

*Prilagodljivo ocenjevanje morfoloških lastnosti  
dolgih ambulantnih elektrokardiogramov z uporabo  
ortogonalnih transformacij*

Miha Amon

DOKTORSKA DISERTACIJA

PREDANA

FAKULTETI ZA RAČUNALNIŠTVO IN INFORMATIKO

KOT DEL IZPOLNJEVANJA POGOJEV ZA PRIDOBITEV NAZIVA

DOKTOR ZNANOSTI

S PODROČJA

RAČUNALNIŠTVA IN INFORMATIKE



Ljubljana, 2017



## IZJAVA

*Izjavljam, da sem avtor dela in da slednje ne vsebuje materiala, ki bi ga kdorkoli predhodno že objavil ali oddal v obravnavo za pridobitev naziva na univerzi ali na drugem visokošolskem zavodu, razen v primerih, kjer so navedeni viri.*

— Miha Amon —  
september 2017

ODDAJO SO ODOBRILI

dr. Franc Jager

*profesor za računalništvo in informatiko*

MENTOR IN ČLAN OCENJEVALNE KOMISIJE

dr. Franc Solina

*profesor za računalništvo in informatiko*

PRESEDNIK OCENJEVALNE KOMISIJE

dr. Bojan Orel

*profesor za računalništvo in informatiko*

ČLAN OCENJEVALNE KOMISIJE

dr. Andrej Žemva

*profesor za elektrotehniko*

ČLAN OCENJEVALNE KOMISIJE





## PREDHODNA OBJAVA

Izjavljam, da so bili rezultati obravnavane raziskave predhodno objavljeni/sprejeti za objavo v recenzirani reviji ali javno predstavljeni v naslednjih primerih:

- [1] M. Amon and F. Jager. Electrocardiogram st-segment morphology delineation method using orthogonal transformations. *PLoS ONE*, 11(2), 02 2016.  
doi: [10.1371/journal.pone.0148814](https://doi.org/10.1371/journal.pone.0148814).

Potrjujem, da sem pridobil pisna dovoljenja vseh lastnikov avtorskih pravic, ki mi dovoljujejo vključitev zgoraj navedenega materiala v pričujočo disertacijo. Potrjujem, da zgoraj navedeni material opisuje rezultate raziskav, izvedenih v času mojega diplomskega študija na Univerzi v Ljubljani.



## POVZETEK

Nezanesljiv opis prehodnih morfoloških sprememb segmenta ST v dolgotrajnih ambulantnih elektrokardiografskih (EKG) posnetkih in nezanesljivo razlikovanje med prehodnimi ishemičnimi ter neishemičnimi spremembami morfologij segmenta ST sta še vedno šibkejši lastnosti današnjih sistemov za vizualno ali avtomatsko odkrivanje epizod prehodne ishemije. Tradicionalna metoda ocenjevanja prehodnih sprememb morfologije segmenta ST, ki temelji na merjenju nivoja segmenta ST v zgolj eni sami statični referenčni točki, ni dovolj natančna metoda, ne le zaradi številnih motenj, ki so prisotne v signalih EKG, ta metoda namreč ne zajame morfologije celotnega segmenta ST. Posebna težava, ki do sedaj še ni bil ustrezno rešena, je tudi spremenljiva dolžina posameznih segmentov in valov znotraj posameznih srčnih utripov zaradi spreminjajoče se srčne frekvence. Klinično pomembni segmenti in valovi signala EKG lahko tako ob spremenjeni srčni frekvenci nastopijo v znatno spremenjeni časovni dolžini. Dogaja se, da so opazovane značilnosti segmentov in valov klinično ekvivalentne, ocena njihove morfologije pa je zaradi spremenjene srčne frekvence bistveno različna. Obstoječe metode za izločanje morfoloških značilk segmenta ST niso prilagodljive glede na spreminjajočo se srčno frekvenco in posledično na spreminjajočo se dolžino segmenta ST.

Razvili smo novo, robustno, proti motnjam odporno metodo za opisovanje prehodnih sprememb morfologij segmenta ST in novo metodo za klasifikacijo prehodnih ishemičnih ter neishemičnih epizod segmenta ST, ki temeljita na ortogonalnih transformacijah, ki se dinamično prilagajajo spreminjajoči se srčni frekvenci. V ta namen smo razvili nov algoritem, ki s prevzorčenjem in linearno interpolacijo vhodnih vektorjev vzorcev (segmenti ST) dinamično prilagaja njihovo dolžino glede na višino trenutne srčne frekvence in jih transformira v vektorje vzorcev enotne dolžine. Algoritem temelji na Bazettovi formuli, ki je namenjena ocenjevanju dolžine intervala depolarizacije

in repolarizacije srčnih ventriklov glede na trenutno srčno frekvenco in na nekaj ekspertno določenih položajih prilagodljive referenčne točke merjenja nivoja segmenta ST v odvisnosti od nekaterih izbranih vrednosti srčne frekvence. Z namenom prilagodljivega in proti motnjam odpornega zajemanja in ocenjevanja morfoloških lastnosti dolgotrajnih posnetkov EKG smo z uporabo robustnega postopka izgradnje kovariančne matrike, ki se tudi dinamično prilagaja spreminjajoči se dolžini vhodnih vektorjev vzorcev, razvili nove bazne funkcije ortogonalne transformacije Karhunen in Loève (KLT) za segment ST ter novo ortogonalno transformacijo za segment ST na osnovi Legendrovih polinomov (LPT), ki se prav tako dinamično prilagaja spreminjajoči se dolžini vhodnih vektorjev vzorcev zaradi spreminjajoče se srčne frekvence. Transformaciji KLT in LPT dajeta konsistentne medsebojno primerljive ocene sprememb morfologij segmenta ST ne glede na spremembe v srčni frekvenci. Pridobljene časovne vrste vektorjev morfoloških značilk obeh transformacij omogočajo tudi nadaljnjo ekspertno analizo in avtomatsko detekcijo ter klasifikacijo prehodnih epizod segmenta ST.

Razvita metoda opisovanja omogoča dolgotrajno reprezentacijo in karakterizacijo prehodnih sprememb morfologij segmenta ST na osnovi časovnih vrst vektorjev diagnostičnih in morfoloških značilk. V delu predstavljamo študijo zmogljivosti nove metode za reprezentacijo in karakterizacijo prehodnih sprememb morfologij ishemičnih in neishemičnih epizod segmenta ST z uporabo transformacije KLT ali LPT. Prve tri bazne funkcije transformacije LPT (konstanta, linearna funkcija in kvadratna funkcija) ustrezajo klinično pomembnim kategorijam morfologij, ki se pojavljajo pri prehodnih spremembah morfologije segmenta ST ob srčni ishemiji (elevacija ali depresija, nagib in ukrivljanje). Transformacija LPT tako omogoča edinstven neposreden vpogled v posamezne kategorije sprememb morfologij segmenta ST v časovnem prostoru le preko spremljanja časovnih vrst vektorjev morfoloških značilk. Izdelane nove časovne vrste vektorjev morfoloških značilk transformacij KLT in LPT smo objavili tudi v okviru mednarodne referenčne podatkovne baze LTST DB (Long-Term ST Database) dolgotrajnih posnetkov EKG, ki je prosto dostopna na spletnem portalu PhysioNet.

Razvita metoda klasifikacije prehodnih ishemičnih in neishemičnih epizod segmenta ST temelji na uporabi samo vektorjev morfoloških značilk transformacije KLT ali LPT in ne uporablja drugih vektorjev diagnostičnih značilk signala EKG. Druge prednosti razvite metode pred drugimi obstoječimi metodami so še: nižja občutljivost na motnje, za vsak srčni utrip je potrebna le stabilna referenčna točka za ta utrip, točnega

začetka segmenta ST za vsak srčni utrip ni treba detektirati, prav tako informacija o času začetka prehodne epizode ni potrebna. V delu predstavljamo študijo vrednotenja zmogljivosti klasifikacije ekspertno označenih prehodnih ishemičnih in neishemičnih epizod posnetkov podatkovne baze LTST DB z uporabo novih vektorjev morfoloških značilk transformacij KLT ali LPT ter z uporabo nekaterih izbranih standardnih klasifikatorjev. Najvišja dosežena klasifikacijska točnost, ob uporabi klasifikatorja k najbližjih sosedov, kNN ( $k = 3$ ), dobljena z desetkratnim prečnim preverjanjem in desetimi ponovitvami, je na osnovi KLT 91% in na osnovi LPT 90%, kar je primerljivo in boljše od objavljenih zmogljivosti sorodnih študij.

Prilagodljivi ortogonalni transformaciji KLT in LPT prinašata nove možnosti za učinkovitejšo ekspertno diagnostiko in avtomatsko analizo. Transformacija KLT daje višje rezultate zmogljivosti klasifikacije med prehodnimi ishemičnimi in neishemičnimi epizodami segmenta ST ter nakazuje razvoj novih in zmogljivejših avtomatskih sistemov. Transformacija LPT daje boljše rezultate opisovanja prehodnih sprememb morfologij segmenta ST in nakazuje možnosti razvoja novih kliničnih diagnostičnih kriterijev za diagnosticiranje prehodne ishemije.

*Ključne besede:* ambulantni elektrokardiogram, podatkovna baza ambulantnih posnetkov (Long-Term ST Database, LTST DB), transformacija Karhunen in Loève (KLT), ortogonalna transformacija na osnovi Legendrovih polinomov (LPT), prilagodljivo ocenjevanje dolžine segmenta ST, opisovanje prehodnih sprememb morfologij segmenta ST, klasifikacija prehodnih epizod segmenta ST



## ABSTRACT

The unreliable delineation of transient morphologic changes of ST segments in long-term ambulatory electrocardiogram (ECG) records and the unreliable differentiation between transient ischaemic and non-ischaemic ST segment morphologies are still the major weakness of modern systems for the visual or automatic detection of transient ischaemic episodes. The traditional method for assessing transient changes of ST segment morphologies, which is based on the ST segment level measurement in a single static reference point, is not a sufficiently precise technique, not only due to frequent noises present in the ECG signals, but also because this method does not acquire the morphology of an entire ST segment. A particular problem that has not been suitably resolved as of yet is the variable length of individual segments and waves of individual heartbeats due to variable heart rates. Clinically important segments and waves of the ECG signal can therefore appear in significantly modified time lengths due to changed heart rates. What occurs is that the observed characteristics of segments and waves are clinically equivalent, but the assessment of their morphology is significantly different due to a changed heart rate. The existing methods for ST segment morphology feature extraction are not adaptive with regard to variable heart rates and consequently to variable ST segment lengths.

We have developed a new, robust, noise-resistant method for the delineation of transient ST segment morphology changes, and a new method for the classification of transient ischaemic and non-ischaemic ST segment episodes, which are based on a foundation of orthogonal transformations that dynamically adapt to the variable heart rate. For this purpose, we have developed a new algorithm which dynamically by re-sampling and the linear interpolation of the input pattern vectors (ST segments) adapts their length with regard to the value of instantaneous heart rate, and transforms them into pattern vectors with a constant length. The algorithm is based on Bazett's formula,

which is used for estimating the length of the interval of depolarization and repolarization of heart ventricles according to instantaneous heart rate, and on a few expertly determined positions of adaptive reference point of measurement of the ST segment level with regard to several selected values of heart rate. With the aim of establishing an adaptive and noise-resistant extraction and estimation of morphologic features of long-term ECG records, we have developed new basis functions of the Karhunen-Loève orthogonal Transformation (KLT) for the ST segment using a robust covariance matrix construction procedure, which also dynamically adapts to the variable length of the input pattern vectors, and a new orthogonal transformation for the ST segment on the basis of the Legendre polynomials (LPT), which also dynamically adapts to the variable length of the input pattern vectors due to variable heart rates. The KLT and LPT transformations yield consistent mutually comparable estimations of the ST segment morphology changes regardless of the changes in heart rate. The obtained morphology feature-vector time series of both transformations further enable expert analysis and the automatic detection and classification of transient ST segment episodes.

The developed delineation method enables a long-term representation and characterization of transient ST segment morphology changes on the basis of diagnostic and morphologic feature-vector time series. We present a performance study of the new method for the representation and characterization of transient ischaemic and non-ischaemic ST segment morphology changes using the KLT and LPT transformations. The first three basis functions of the LPT transformation (constant, linear function, and quadratic function) correspond to clinically important morphology categories that occur during transient ST segment morphology changes of heart ischaemia (elevation or depression, slope, and scooping). The LPT transformation thus enables a unique direct insight into the individual time domain categories of the ST segment morphology changes via monitoring only the morphologic feature-vector time series. We have published the new derived KLT and LPT transformation-based morphologic feature-vector time series in the scope of the international reference database LTST DB (Long-Term ST Database) of long-term ECG records, which is freely available on the Physionet website.

The method developed for the classification of transient ischaemic and non-ischaemic ST segment episodes is based on the use of the KLT or LPT transformation morphologic feature vectors only and does not use other diagnostic feature vectors of the ECG signal. The other advantages of the developed method over the other existing methods



are: lower sensitivity to noise, only a stable fiducial point is needed for each heartbeat, there is no need to detect the precise beginning of ST segment for each heartbeat, while the information on the start time of a transient episode is also not needed. In our work we present a study on the performance evaluation of classification of expert-annotated transient ischaemic and non-ischaemic episodes from LTST DB database records using new morphologic feature vectors of the KLT and LPT transformation, and using a few selected standard classifiers. The highest classification accuracy achieved, using the  $k$  Nearest Neighbors classifier,  $kNN$  ( $k = 3$ ), obtained by ten-fold cross-validation and ten repetitions, was 91% based on the KLT and 90% based on the LPT, which is comparable and better than the published performances from related studies.

The adaptive KLT and LPT orthogonal transformations open new possibilities for a more efficient expert diagnosis and automated analysis. The KLT transformation yields higher results in classification performance between transient ischaemic and non-ischaemic ST segment episodes and indicates the development of new and more powerful automated systems. The LPT transformation yields better results in the delineation of transient ST segment morphology changes and indicates opportunities for the development of new clinical diagnostic criteria for diagnosing transient ischaemia.

*Key words:* Ambulatory electrocardiogram, Long-term ambulatory database (Long-Term ST Database, LTST DB), Karhunen-Loève Transformation (KLT), Legendre-Polynomial based orthogonal Transformation (LPT), Adaptive estimation of ST-segment length, Delineation of transient ST-segment morphology changes, Classification of transient ST-segment episodes



## ZAHVALA

*Zahvaljujem se mentorju prof. dr. Francu Jagru za vse usmeritve, napotke, vložen čas in številne dragocene nasvete, brez katerih to delo ne bi bilo mogoče.*

*Zahvaljujem se družbi Infonova d.o.o., ki je financirala moj doktorski študij, prav tako pa tudi vsem sodelavcem za podporo ob delu, marsikatero idejo, kritično mnenje in razvedrilo ob najbolj pravih trenutkih.*

*Zahvaljujem se agenciji ATE Globalis d.o.o. in lektorici profesorici Aleksandri Gačič za natančne lekture besedil tega dela.*

*Hvala vsem prijateljem in družini, ste moj navdih in energija!*

— Miha Amon, Ljubljana, september 2017.



# KAZALO

<i>Povzetek</i>	<i>i</i>
<i>Abstract</i>	<i>v</i>
<i>Zahvala</i>	<i>ix</i>
<b>1 Uvod</b>	<b>1</b>
1.1 Izvirni prispevki k znanosti . . . . .	9
1.1.1 Algoritem za ocenjevanje spreminjajoče se dolžine segmenta ST elektrokardiograma v odvisnosti od spreminjajoče se srčne frekvence . . . . .	9
1.1.2 Metoda za opisovanje značilnih sprememb morfologije segmenta ST elektrokardiograma na osnovi spreminjajoči se srčni frekvenci prilagodljivih ortogonalnih transformacij KLT ali LPT	10
1.1.3 Metoda za klasifikacijo med prehodnimi ishemičnimi in neishemičnimi epizodami segmenta ST elektrokardiograma na osnovi spreminjajoči se srčni frekvenci prilagodljivih ortogonalnih transformacij . . . . .	11
<b>2 Pregled področja in problematike</b>	<b>13</b>
2.1 Elektrokardiogram . . . . .	14
2.2 Prehodna srčna ishemija . . . . .	16
2.3 Epizode odstopanj segmenta ST in njihove morfološke značilnosti . .	19
2.4 Ocenjevanje morfologije segmenta ST in ortogonalne transformacije	20

2.5	Vpliv spreminjajoče se srčne frekvenca na ocenjevanje morfolologije segmenta ST . . . . .	25
2.6	Izločanje značilnk in predstavitev oblik segmenta ST v dolgih elektrokardiogramih . . . . .	28
2.7	Orodja in gradiva . . . . .	30
2.7.1	Podatkovna baza elektrokardiografskih posnetkov European Society of Cardiology ST-T Database (ESC DB) . . . . .	30
2.7.2	Podatkovna baza elektrokardiografskih posnetkov Long-term ST Database (LTST DB) . . . . .	31
2.7.3	Okolje za delo s fiziološkimi signali Waveform Database . . . . .	33
3	<i>Analiza signalov EKG s prilagodljivimi ortogonalnimi transformacijami</i> . . . . .	35
3.1	Diskretna ortogonalna transformacija . . . . .	37
3.2	Ortogonalna transformacija kot analitsko orodje . . . . .	39
3.3	Zmanjšanje dimenzije transformiranega prostora . . . . .	40
3.4	Dinamično prilagajanje dolžine vzorčnih vektorjev . . . . .	43
3.4.1	Ocena časovne zahtevnosti implementacije . . . . .	47
3.5	Ocenjevanje dolžine segmenta ST na osnovi srčne frekvenca . . . . .	48
4	<i>Prilagodljiva transformacija Karhunen in Loève</i> . . . . .	57
4.1	Ortogonalna transformacija KLT . . . . .	58
4.2	Mahalanobisova razdalja . . . . .	64
4.3	Gradnja kovariančne matrike z vektorji učnih vzorcev prilagodljive dolžine . . . . .	64
4.4	Izdelava novih baznih funkcij KLT za segment ST . . . . .	66
4.4.1	Ocena časovne zahtevnosti implementacije in časa izvajanja analiz . . . . .	70
4.5	Izračun koeficientov transformacije KLT z dinamičnim prilagajanjem dolžine vzorčnih vektorjev . . . . .	73
4.5.1	Ocena časa izvajanja analiz . . . . .	74
5	<i>Prilagodljiva transformacija na osnovi Legendrovih polinomov</i> . . . . .	75
5.1	Zasnova ortogonalne transformacije LPT . . . . .	77
5.2	Preizkus ortogonalnosti . . . . .	81
5.3	Ortogonalna transformacija LPT . . . . .	81

5.4	Mahalanobisova razdalja . . . . .	82
5.5	Izračun koeficientov transformacije LPT z dinamičnim prilagajanjem dolžine vzorčnih vektorjev . . . . .	83
5.5.1	Ocena časa izvajanja analiz . . . . .	84
6	<i>Izdelava časovnih vrst vektorjev morfoloških značilnk</i> . . . . .	85
6.1	Predobdelava signalov EKG in izločanje časovnih parametrov . . . . .	86
6.2	Izdelava časovnih vrst vektorjev diagnostičnih značilnk . . . . .	87
6.3	Izbira dimenzije transformiranega prostora KLT in LPT . . . . .	88
6.4	Izdelava časovnih vrst vektorjev morfoloških značilnk s prilagodljivimi KLT in LPT na posamičnih odvodih LTST DB . . . . .	89
6.5	Ocena časa izvajanja analiz . . . . .	94
7	<i>Evaluacija novih algoritmov in metod</i> . . . . .	97
7.1	Algoritem za dinamično ocenjevanje dolžine segmenta ST na osnovi srčne frekvence . . . . .	98
7.2	Opisovanje oblik prehodnih epizod segmenta ST elektrokardiograma s prilagodljivimi KLT in LPT . . . . .	102
7.3	Klasifikacija med prehodnimi ishemičnimi in neishemičnimi epizoda- mi segmenta ST . . . . .	117
8	<i>Razprava</i> . . . . .	133
8.1	Algoritem za dinamično prilagajanje dolžine vhodnih vzorčnih vektor- jev segmenta ST spreminjajoči se srčni frekvenci . . . . .	134
8.2	Metoda za ocenjevanje značilnih sprememb morfologije segmenta ST na osnovi spreminjajoči se srčni frekvenci prilagodljivih transformacij KLT in LPT. . . . .	134
8.3	Metoda za klasifikacijo med prehodnimi ishemičnimi in neishemični- mi epizodami segmenta ST na osnovi srčni frekvenci prilagodljivega izločanja morfoloških značilnk . . . . .	136
9	<i>Zaključek</i> . . . . .	141
9.1	Nadaljnje delo . . . . .	143

<i>xiv</i>	Kazalo	M. Amon
<i>10</i>	<i>Priloge</i>	<i>145</i>
	10.1 Priloga 1 . . . . .	<i>146</i>
	<i>Literatura</i>	<i>155</i>




# *Uvod*

Elektrokardiogram (EKG) je zapis električne aktivnosti srčne mišice, izmerjen kot časovni potek električnega potenciala med elektrodami, nameščenimi na telesu pacienta. Prvi elektrokardiogram je na začetku 20. stoletja posnel Willem Einthoven z nitnim galvanometrom [1]. Električno aktivnost srca lahko predstavimo z modelom srednjega električnega srčnega vektorja [2, 3]. Velikost in smer srednjega električnega srčnega vektorja se s časom spreminja kot posledica razelektritvenega vala, ki se širi vzdolž srčne mišice. Električne napetosti, ki jih izmerimo med elektrodami, nameščenimi na telesu pacienta, ustrezajo projekcijam srednjega električnega srčnega vektorja na osi, ki potekajo skozi točke, na katerih so nameščene elektrode. Položaji elektrod za to meritev so standardizirani in jih imenujemo tudi odvodi. Graf časovnega poteka napetosti, merjene na takem odvodu, nam da značilno krivuljo EKG srčnega utripa.

Na sliki 1.1.A je ilustriрана srčna mišica v posameznih fazah enega srčnega utripa, poleg pa so izrisani grafi EKG tega srčnega utripa. EKG srčnega utripa tipično sestavlja pet valov, ki so poimenovani s črkami P, Q, R, S in T (označeni s črkami na grafih). Na sliki so intervali elektrokardiograma, ki ustrezajo posamezni fazi srčnega utripa, izrisani z rdečo črto na grafih. Srčni utrip se začne z električnim impulzom, ki izvira v sinoatrialnem vozlu (slika 1.1.B) in se nadaljuje z depolarizacijo srčnih atrijev (predvorov). Ta se na EKG vidi kot val P (glej tudi sliko 1.2) in v srcu sproži krčenje atrijev. Za tem pride do depolarizacije srčnih ventriklov (prekatov), ki se na elektrokardiogramu vidi kot zaporedje valov Q, R in S. To imenujemo tudi kompleks QRS. Posledično pride do krčenja srčnih ventriklov. Po depolarizaciji ventriklov in pred njihovo repolarizacijo, ki se na EKG odraža kot val T, preteče nekaj časa, ko v srcu navadno ni zaznati izrazite električne aktivnosti. Ta interval elektrokardiograma med valoma S in T imenujemo *segment ST*.

Ambulantno snemanje elektrokardiograma in analize dolgotrajnih (24 ur) posnetkov EKG, pridobljenih med vsakodnevnimi dejavnostmi pacientov, danes predstavljajo temeljne neinvazivne metode v kardiološki diagnostiki. So ključnega pomena v diagnostiki simptomatskih in asimptomatskih (tihih) stanj pomanjkljive oskrbe srčnih tkiv s kisikom ali t. i. ishemije. Ta lahko vodi do miokardnega infarkta, posledično pa do smrti.


Ker so tovrstni posnetki EKG razmeroma dolgi (tipično 24 ur ali več) in tako vsebujejo velike količine podatkov, hkrati pa pogosto vsebujejo različne vrste motenj znatnih jakosti, je diagnostika na njihovi osnovi zahteven proces. Zato je izjemnega pomena razvoj računalniških metod za avtomatsko robustno izločanje diagnostičnih in morfo-



Slika 1.1

A) Delovanje in električna aktivnost srca med srčnim utripom, ki se odraža v posamičnih intervalih elektrokardiograma, kot ga zajamemo z elektrodami na površju telesa preiskovanca (pacienta). Vir: prosto dostopno na <http://cnx.org/content/col11496/1.4>.

B) Anatomija srčne mišice [5].



Slika 1.2

Prikaz EKG enega srčnega utripa. Označeni so pomembni intervali in točke v poteku EKG srčnega utripa.


loških značilnk za vsak srčni utrip, ki nato služijo tako za učinkovitejšo diagnostiko s strani ekspertov kardiologov kot tudi za avtomatske detekcijske sisteme. S pridobljenimi značilnkami lahko tvorimo časovne vrste, ki omogočajo učinkovito spremljanje prehodnih sprememb morfologije valov in segmentov signala EKG. Takšne avtomatizirane analize so izjemnega pomena kliničnim ekspertom pri zgodnjem ocenjevanju resnosti srčne ishemije, pri natančni interpretaciji povezanih kliničnih dogodkov ter pravočasni in ustrezni terapiji pacientov [2].

V okviru tega dela se osredotočamo na posebno pomemben predel v časovnem poteku elektrokardiograma srčnega utripa – segment ST (slika 1.2). Nahaja se med kolonom za točko S v signalu EKG, kjer se signal začne izravnnavati (koleno J), in začetkom vala T. Segment ST nastopi po depolarizaciji srčnih ventriklov (kompleks QRS) in se konča pred njihovo repolarizacijo (val T). Segment ST nosi ključne informacije o patoloških ishemičnih procesih v srčni mišici [2, 6, 7]. Segment ST je vsebovan v intervalu QT elektrokardiograma srčnega utripa, ki predstavlja celoten proces depolarizacije in ponovne repolarizacije srčnih ventriklov.

Na sliki 1.3 sta prikazana dva tipična izseka iz dolgotrajnih posnetkov EKG. Zgornji predel (slika 1.3.A) prikazuje prehodno epizodo odstopajoče morfologije segmenta ST,

ki je kompatibilna s prehodno ishemijo. Jasno vidna sta tudi prehodno povečanje srčne frekvence in prehodna sprememba morfologije vala T. V spodnjem predelu (slika 1.3.B) je prikazan primer motenj v posnetku EKG. Tovrstne motnje predstavljajo zahtevno težavo tako za vizualno kot avtomatsko ocenjevanje prisotnosti in intenzivnosti ishemičnih epizod segmenta ST. V poglavju 2 bomo podrobneje predstavili značilnosti elektrokardiograma in segmenta ST elektrokardiograma ter do sedaj preizkušene in uveljavljene metode za detekcijo in analizo prehodnih sprememb in epizod segmenta ST.

Temelj avtomatske analize fizioloških signalov so metode za učinkovito ocenjevanje morfologije pojavov v signalih z morfološkimi značilkami, ki jih pridobimo iz vzorčnih signalov. V dosednji praksi so se na področjih avtomatske analize segmenta ST elektrokardiograma, poleg tradicionalnejših pristopov z merjenjem diagnostičnih parametrov neposredno v časovnem prostoru, kot učinkoviti izkazali pristopi z računskimi transformacijami segmenta ST. Najbolj se je uveljavila ortogonalna transformacija Karhunen in Loève (KLT). Z uporabo ortogonalnih transformacij (opisano v poglavju 3) zajamemo informacijo s celotnega časovnega poteka segmenta ST in jo uporabimo za ocenjevanje njegovih morfoloških lastnosti. Takšno ocenjevanje je hkrati manj občutljivo na drobne lokalne motnje in morfološke posebnosti v segmentu ST, saj lahko pričakujemo učinkovitejši zajem koristne informacije o morfoloških lastnostih celotnega segmenta ST. Slednje so namreč primarnega pomena pri diagnostiki in analizah



Slika 1.3

A) Začetek, ekstrem in konec (od zgoraj navzdol) prehodne epizode segmenta ST kompatibilne z ishemijo. B) Izrazite motnje v posnetku signala EKG.

ekspertov kardiologov [6, 7], pa tudi pri avtomatski detekciji.

Rezultati na področjih avtomatske analize signalov EKG so v zadnjem obdobju s številnimi tehnikami podrobne priprave in obdelave morfoloških značilk dosegli velik napredek v natančnosti. A kljub vsemu se pojavljajo meje, denimo v točnosti klasifikacije različnih klinično pomembnih pojavov v signalih EKG, ki jih sedanji sistemi s težavo presegajo. Zato se danes tovrstne rešitve razmeroma nezadostno uvajajo v klinično prakso. Tako smo ocenili, da bi izboljšave temeljnih metod za ocenjevanje morfologije segmenta ST elektrokardiograma lahko prinesle pomemben prispevek na poti k izboljševanju zmogljivosti sistemov za avtomatske analize.

Posebno izrazita in še nerešena težava pri zajemanju morfoloških značilk v avtomatski analizi signalov EKG je spreminjajoča se srčna frekvenca. Ta namreč znatno vpliva na trajanje segmenta ST v elektrokardiogramu. Pri tem fiziološki procesi v ozadju lahko sodijo v povsem iste razrede, le da se hitrost njihovega poteka in s tem njihovo trajanje spreminjata. Posledica je, da se s tem spremeni tudi dolžina segmenta ST, izražena v številu časovnih vzorcev, saj vhodni signal vzorčimo s konstantno frekvenco vzorčenja. Če želimo nato takšne segmente ST zajemati v vektorje vzorcev za obdelavo z ortogonalno transformacijo, naletimo na težavo, da njihova dolžina (tj. število časovnih vzorcev, ki jih sestavljajo) ni enotna. Ortogonalna transformacija namreč po definiciji transformira le vhodne vektorje enotne (konstantne) dolžine. Če vhodne vektorje poročemo na enotno dolžino, lahko preučevani pojav, kakršen je segment ST, zajamemo nenatančno ali pomanjkljivo. Izpustimo lahko klinično pomemben del, če je trajanje segmenta ST zaradi zelo nizke srčne frekvence preseglo konstantno dolžino vhodnega vektorja. V primeru povečane srčne frekvence in posledično krajšega trajanja lahko zajamemo še dodaten signal, ki nima kliničnega pomena in predstavlja motnjo. Hkrati se znatno spremeni (popači) tudi sama ocena morfologije z ortogonalno transformacijo, kot razložimo v nadaljevanju.

Možna strategija je, da se s tem sprijaznimo. Tako delujejo dosedANJI sistemi. V nadaljevanju bomo pokazali, da takšna poenostavitev povzroča zahtevne težave, ki se jih nemara razvijalci sistemov do sedaj sploh niso v celoti zavedali. Pojav spreminjajoče se dolžine vhodnih vzorcev ob spreminjajoči se srčni frekvenci tako preprečuje natančno zaznavanje morfologije z ortogonalnimi transformacijami. Pri tradicionalnih metodah s točkovnim merjenjem v časovnem prostoru lahko povzroči celo povsem napačne meritve. Prav tako spreminjajoča se srčna frekvenca onemogoča že tudi natančen izračun baznih funkcij za transformacijo KLT. Algoritem za izdelavo slednjih namreč deluje na

osnovi kovariančne matrike vektorjev učnih vzorcev (segmentov ST), pri katerih srčna frekvenca in trajanje prav tako nista statična. Spreminjajoča se srčna frekvenca tako v sedANJI klinični praksi predstavlja pomembno težavo pri zanesljivem ocenjevanju dejanske oblike segmenta ST in v nadaljnjih avtomatskih detekcijskih postopkih; denimo ugotavljanje nastopa ishemije in razločevanje od "lažnih", neishemičnih, dogodkov.

V poglavju 3 zato postavimo temelje diskretne ortogonalne transformacije, katere širino okna zajema vhodnih podatkov (tj. dolžino vhodnih vzorčnih vektorjev) lahko s pomočjo prevzorčenja na vhodu dinamično prilagajamo v skladu z dodatnim parametrom, kot je srčna frekvenca. Ker dosedANJI algoritmi niso upoštevali spreminjajoče se časovne dolžine segmenta ST ob spreminjajoči se srčni frekvenci, so viri na področju metod za določitev dolžine segmenta ST na osnovi srčne frekvence razmeroma omejeni. V ta namen smo razvili algoritem, ki ga v poglavju 3 izpeljemo na osnovi dveh pristopov:

- Tradicionalne empirično razvite Bazettove formule [8], ki se v kardiologiji uporabljajo za korekcijo izmerjene dolžine intervala QT elektrokardiograma (slika 1.2) pri diagnostiki t. i. sindroma dolge dobe QT [9], kadar se srčna frekvenca razlikuje od standardne diagnostične:

$$QT_C = \frac{QT}{\sqrt{RR}}, \quad (1.1)$$

kjer je  $QT_C$  korigirana dolžina intervala QT, izmerjeno dolžino intervala QT, izraženo v sekundah, pa označimo kot  $QT$ .  $RR$  pomeni razdaljo med valom R analiziranega srčnega utripa in valom R srčnega utripa, ki mu sledi, izraženo v sekundah. Dolžina intervala  $RR$  je obratno sorazmerna s srčno frekvenco. Ker interval QT vsebuje segment ST, kot je razvidno na sliki 1.2, iz Bazettove formule izpeljemo oceno dolžine segmenta ST ob izmerjeni srčni frekvenci.

- Ekspertno določenih referenčnih položajev točke merjenja nivoja segmenta ST (znotraj segmenta ST) pri nekaterih vrednostih srčne frekvence. Te referenčne položaje so postavili eksperti kardiologi ob razvoju podatkovne baze LTST DB [10] v skladu z različnimi vrednostmi srčne frekvence.

V poglavju 4 predstavimo algoritem za robustno generiranje kovariančne matrike in izračun baznih funkcij za transformacijo KLT, v katerega prav tako uvajamo nov

pristop z dinamičnim prilagajanjem širine okna za zajem učnih vzorcev glede na spreminjajočo se srčno frekvenco. Nato predstavimo še postopek izračunavanja časovnih vrst koeficientov transformacije KLT, ki smo ga nadgradili z dinamičnim prilagajanjem srčni frekvenci.

Pri baznih funkcijah KLT za segment ST smo zaznali podobnosti v njihovih oblikah z nekaterimi družinami ortogonalnih polinomov, kot so Legendrovi polinomi. Predstavitev oblik segmenta ST s takšno matematično osnovano skupino baznih funkcij kaže pomembne prednosti na področjih avtomatske in ročne analize signalov EKG. Bistveno pa je, da te čiste elementarne funkcije opisujejo klinično pomembne patološke ishemične spremembe v morfologiji, kot jih navaja kardiologija (elevacija ali depresija, nagib navzgor ali navzdol ter ukrivljanje segmenta ST) [10], kar v prostoru značilk. Tako omogočajo neposreden vpogled v prehodne spremembe morfologije segmenta ST v časovnem prostoru. Zato smo zasnovali novo diskretno ortogonalno transformacijo segmenta ST na osnovi Legendrovih polinomov (LPT), ki jo predstavimo v poglavju 5. Prav tako smo razvili algoritem za izračunavanje časovnih vrst vektorjev morfoloških značilk na osnovi LPT s prilagodljivo širino okna transformacije glede na srčno frekvenco.

Nove metode za prilagodljivo ocenjevanje morfologij segmenta ST elektrokardiograma smo uporabili za izračun novih časovnih vrst vektorjev morfoloških značilk za vse posnetke največje mednarodne referenčne podatkovne baze ekspertno označenih elektrokardiografskih posnetkov LTST DB [10]. Z novimi transformacijami smo izdelali časovne vrste vektorjev morfoloških značilk za celotno podatkovno bazo LTST DB. Nove časovne vrste vektorjev morfoloških značilk KLT in LPT, izdelane z algoritmi s konstantno širino okna transformacije, smo objavili v mednarodni referenčni podatkovni bazi LTST DB, kjer v času nastanka tega dela pripravljamo tudi objavo morfoloških časovnih vrst, ki so izdelane z najnovejšimi prilagodljivimi algoritmi. Podatkovna baza LTST DB je javno dostopna na strežniku Physionet, osrednjem mednarodnem spletnem mestu za standardizirane in nestandardizirane podatkovne baze z biomedicinskimi vzorci ter pripadajočo programsko opremo. Ureja, vzdržuje in posodablja ga Massachusettski inštitut za tehnologijo (MIT) in ga financirajo Ameriški inštituti za zdravje (NIH). V poglavju 6 predstavimo tehnike priprave vhodnih podatkov in obdelave do končne izdelave novih časovnih vrst vektorjev morfoloških značilk segmenta ST na osnovi prilagodljivih transformacij KLT in LPT.

Razvili smo novo metodo za ocenjevanje, predstavitev in karakterizacijo prehodnih



sprememb morfolologije segmenta ST ter klinično pomembnih dogodkov v segmentu ST elektrokardiograma. V poglavju 7 karakteriziramo lastnosti in posebnosti različnih tipov morfoloških sprememb pri prehodnih ishemičnih in neishemičnih epizodah segmenta ST. Prav tako analiziramo, kako na različne tipe morfoloških sprememb segmenta ST in na dosedanje ter nove metode za njihovo ocenjevanje vpliva spremenjajoča srčna frekvenca. S pomočjo razvitih algoritmov opisujemo tipe morfoloških sprememb med pravo ishemijo. Zlasti pa smo ob tem preizkusili in medsebojno primerjali vektorje značilk prilagodljivih in neprilagodljivih transformacij KLT in LPT z namenom opredelitve moči nove transformacije LPT v primerjavi s tradicionalno KLT.

V poglavju 7 predstavimo tudi novo metodo za klasifikacijo med ishemičnimi in neishemičnimi epizodami segmenta ST, ki smo jo razvili na osnovi algoritmov za izločanje značilk KLT in LPT. Metoda potrebuje zgolj postavitev stabilne referenčne točke v EKG za vsak srčni utrip in zajem značilk ob ekstremih prehodnih ishemičnih in neishemičnih epizod segmenta ST ter tako za delovanje ne potrebuje določanja položaja kolena J in detekcije začetkov prehodnih epizod. Uporabili smo nabor uveljavljenih klasifikatorjev v okolju MathWorks MATLAB Statistics and Machine Learning Toolbox: Klasifikacijsko drevo (angl. Classification Tree), K najbližjih sosedov (angl. K Nearest Neighbors), Linearno diskriminantno analizo (angl. Linear Discriminant Analysis), Naivni Bayesov klasifikator (angl. Naive Bayes Classifier), Kvadratno diskriminantno analizo (angl. Quadratic Discriminant Analysis) in Metodo podpornih vektorjev (angl. Support Vector Machines) z linearnim ter kvadratnim jedrom. Točnost klasifikacije smo preizkusili z desetkratnim prečnim preverjanjem na ekspertno označenih posnetkih podatkovne baze LTST DB.

## *1.1 Izvirni prispevki k znanosti*

Doktorsko delo kandidata s področja računalniških znanosti izkazuje, da je kandidat sposoben samostojnega opravljanja teoretičnih in praktičnih raziskav v širokem spektru podpodročij računalniških znanosti ali v preseku računalniških znanosti in drugih ved.

### *1.1.1 Algoritem za ocenjevanje spreminjajoče se dolžine segmenta ST elektrokardiograma v odvisnosti od spreminjajoče se srčne frekvence*

Pri analizi fizioloških pojavov s pomočjo ortogonalnih transformacij, kakršni sta transformacija Karhunen in Loève (KLT) ter transformacija na osnovi Legendrovih polinomov (LPT), ki temeljita na vhodnih vektorjih vzorcev enotne dolžine, pogosto

naletimo na težavo, da se časovna dolžina analiziranih vhodnih vektorjev vzorcev od pojavitve do pojavitve spreminja. Časovno spremenljiva dolžina segmenta ST srčnih utripov elektrokardiograma je zaradi spreminjajoče se srčne frekvence pogosto razlog za netočno in nezanesljivo izločanje morfoloških vektorjev značilnik transformacij KLT in LPT ter posledično netočno ekspertno opisovanje ali avtomatsko analiziranje prehodnih sprememb morfologij segmenta ST oziroma analiziranje prehodne srčne ishemije.

Razvili smo nov algoritem, ki s prevzorčenjem in linearno interpolacijo vhodnih vektorjev vzorcev (segmenti ST) dinamično prilagaja njihovo dolžino glede na višino trenutne srčne frekvence in jih transformira v vektorje vzorcev enotne dolžine. Prilagodljivo preračunavanje časovne dolžine segmenta ST v odvisnosti od srčne frekvence temelji na: 1) uveljavljeni Bazettovi formuli, ki je sicer namenjena ocenjevanju diagnostične dolžine intervala depolarizacije in repolarizacije srčnih ventriklov glede na trenutno srčno frekvenco; in 2) na ekspertno določenih položajih prilagodljive referenčne točke merjenja nivoja segmenta ST v odvisnosti od nekaterih izbranih vrednosti srčne frekvence. Segment ST je vsebovan v intervalu depolarizacije in repolarizacije srčnih ventriklov, oziroma je njegov podinterval, položaje prilagodljive referenčne točke merjenja nivoja segmenta ST pa so postavili eksperiti kardiologi med razvojem podatkovne baze LTST DB.

Algoritem dinamičnega prilagajanja dolžine vhodnih vektorjev vzorcev smo uporabili za generacijo kovariančne matrike in izračun baznih funkcij transformacije KLT za segment ST in za izračun izhodnih morfoloških vektorjev značilnik za segment ST ob uporabi transformacij KLT ali LPT. Razvite bazne funkcije transformacije KLT in vhodni vektorji vzorcev za transformaciji KLT ali LPT so enotne izbrane dolžine in vsebujejo informacijo o preučevanih fizioloških pojavih v celoti.

#### *1.1.2 Metoda za opisovanje značilnih sprememb morfologije segmenta ST elektrokardiograma na osnovi spreminjajoči se srčni frekvenci prilagodljivih ortogonalnih transformacij KLT ali LPT*

Razvili smo novo avtomatsko metodo, ki s pomočjo prilagodljivih ortogonalnih transformacij KLT ali LPT glede na višino srčne frekvence omogoča natančnejšo vizualizacijo, reprezentacijo in karakterizacijo značilnih klinično pomembnih sprememb morfologije segmenta ST elektrokardiograma. Z reprezentacijo novih prilagojenih časovnih vrst morfoloških vektorjev značilnik transformacij KLT in LPT je omogočeno natančnejše ekspertno vizualno sledenje spremembam morfologije segmenta ST zaradi

fizioloških procesov v ozadju, še posebej sta omogočena natančnejše ekspertno razpoznavanje in razlikovanje med prehodnimi ishemičnimi ter neishemičnimi epizodami segmenta ST. Še posebno reprezentativno moč imajo časovne vrste vektorjev značilke transformacije LPT. Prve tri bazne funkcije transformacije LPT (konstanta, linearna funkcija, kvadratna funkcija) ustrezajo klinično pomembnim morfologijam, ki se pojavljajo pri prehodnih spremembah morfologije segmenta ST ob srčni ishemiji (elevacija ali depresija, nagib, ukrivljanje). Tako transformacija LPT omogoča edinstven neposredni vpogled in spremljanje posameznih kategorij sprememb morfologije segmenta ST v časovnem prostoru kar preko spremljanja časovnih vrst posameznih koeficientov vektorjev morfoloških značilke. Avtomatska analiza in opisovanje značilnih sprememb morfologije segmenta ST elektrokardiograma z uporabo transformacije LPT nakazuje ta možnosti razvoja novih kliničnih diagnostičnih kriterijev za diagnosticiranje prehodne ishemije. Časovne vrste morfoloških vektorjev značilke transformacij KLT in LPT so bile tudi objavljene v okviru mednarodne referenčne podatkovne baze LTST DB na straneh Physionet.

#### *1.1.3 Metoda za klasifikacijo med prehodnimi ishemičnimi in neishemičnimi epizodami segmenta ST elektrokardiograma na osnovi spreminjajoči se srčni frekvenci prilagodljivih ortogonalnih transformacij*

Dosedanje metode za klasifikacijo med prehodnimi ishemičnimi in neishemičnimi epizodami segmenta ST elektrokardiograma zaradi nestacionarne narave oblik in dolžin individualnih segmentov ter valov znotraj posameznih srčnih utripov zaradi spreminjanja se srčne frekvence uporabljajo številne različne kompleksne ali partikularne rešitve in zahtevne ter manj zmogljive metode za izločanje značilke za klasifikacijo. Nova razvita avtomatska metoda s prilagodljivim zajemanjem morfologij segmenta ST zaradi srčni frekvenci prilagodljivega pokrivanja celotnega segmenta ST z baznimi funkcijami ortogonalnih transformacij zmogljivo in zanesljivo klasificira prehodne epizode segmenta ST samo na osnovi značilke, pridobljenih pri ekstremih prehodnih ishemičnih in neishemičnih epizod segmenta ST. Prednosti razvite metode pred drugimi obstoječimi metodami so še: nižja občutljivost na motnje, za vsak srčni utrip je potrebna le stabilna referenčna točka za ta utrip, točnega začetka segmenta ST (koleno J) ni treba detektirati, prav tako informacija o času začetka prehodne epizode ni potrebna. Dosežena klasifikacijska točnost znaša na osnovi transformacije KLT 91%, in na osnovi transformacije LPT 90%, kar je primerljivo in boljše od objavljenih zmogljivosti drugih obstoječih


metod. Transformacija KLT daje višje rezultate klasifikacije in nakazuje razvoj novih ter zmogljivejših avtomatskih sistemov.

## *Pregled področja in problematike*

## 2.1 Elektrokardiogram

Elektrokardiogram pridobimo kot časovni zapis meritve poteka električnega potenciala med standardiziranimi točkami na telesu pacienta v okolici srca. Takšnim standardiziranim meritvam pravimo tudi odvodi. Grafični prikaz tako zajetega signala posamičnega srčnega utripa v enem odvodu tvori značilno krivuljo, ki jo tipično sestavlja pet valov P, Q, R, S in T (slika 2.1).

Iz oblike poteka elektrokardiograma lahko eksperti kardiologi zaznajo različna kronična in akutna stanja, kot so okvare in anomalije srčne mišice, neustrezna preskrba srčne mišice s kisikom in okvare poteka električnih impulzov skozi srce [2, 6]. Bolezni srca in ožilja sodijo med najpogostejše vzroke smrti v sodobnem svetu. Zato je EKG kot izjemno dostopna (cenena) in danes povsem enostavna metoda za učinkovito



Slika 2.1

Prikaz posnetka EKG enega srčnega utripa z dvema odvodoma. Označeni so pomembni intervali in točke ter mesta zajema diagnostičnih parametrov in morfoloških značilk.

neinvazivno diagnostiko izrednega globalnega pomena. Pogosto pa se pojavijo težave ob pomanjkanju ustreznih treniranih ekspertov kardiologov (posebno v manj razvitih državah). Te težave so pereče tudi v razvitem svetu, saj dolgotrajna diagnostična ali stalna ambulantna elektrokardiografska snemanja tipično proizvajajo za človeško obdelavo neobvladljivo velike količine podatkov. Vendar so takšna dolgotrajna snemanja pogosto neizogibna za učinkovito diagnostiko. Zato je razvoj zanesljivih avtomatskih metod za detekcijo na osnovi EKG danes kritičnega pomena.

Prvi korak v razvoju avtomatskih metod je izločanje tradicionalnih morfoloških in diagnostičnih parametrov [7], denimo srčne frekvence, nivoja segmenta ST v točki merjenja in nagiba segmenta ST na osnovi postavljenih točk merjenja (slika 2.1). Ti algoritmi so ključni del procesa, saj nekatere uporabljamo za krmiljenje v nadaljevanju predstavljenih prilagodljivih algoritmov (npr. srčna frekvenca).

Srčno frekvenco ob posamičnih srčnih utripih  $h(j)$  izmerimo kot

$$h(j) = \frac{1}{RR(j)} , \quad (2.1)$$

kjer  $RR(j)$  določimo z meritvijo dolžine intervala RR med srčnimi utripi kot razdaljo na časovni osi točke R  $j$ -tega srčnega utripa do točke R srčnega utripa  $j + 1$ , izraženo v sekundah.

Po tradicionalni metodi v časovnem prostoru nivo segmenta ST  $s_1(i, j)$  izmerimo kot [10] razliko med nivojem (električne napetosti) signala EKG v točki merjenja pri definiranim odmiku od kolena J in izoelektričnim nivojem (slika 2.1):

$$s_1(i, j) = a_{80(60)}(i, j) - z(i, j) , \quad (2.2)$$

kjer  $i$  predstavlja indeks posamičnega odvoda EKG,  $j$  indeks srčnega utripa v vhodnih podatkih,  $a_{80(60)}(i, j)$  pa nivo v segmentu ST signala EKG.  $z(i, j)$  predstavlja izoelektrični nivo, ki ga izmerimo kot nivo signala EKG v sredini najbolj ravnega dela intervala PQ (tj. predel med valoma P in Q v signalu EKG, kjer se signal izravna). Pozicija točke merjenja nivoja segmenta ST  $J+80(60)$  ms je odvisna od srčne frekvence pri opazovanem srčnem utripu  $h$  in je pri frekvenci manjši od 100 utripov na minuto, postavljena 80 ms za kolenom J, pri frekvenci med 100 in 110 utripov na minuto je postavljena 72 ms za kolenom J, pri frekvenci med 110 in 120 utripov na minuto 64 ms za kolenom J in pri frekvenci večji od 120 utripov na minuto 60 ms za kolenom J.

Nagib segmenta ST  $s_s(i, j)$  merimo po tradicionalni metodi v časovnem prostoru kot razliko med nivojem EKG v točki merjenja J+80(60) ms in nivojem EKG v točki J+20 ms:

$$s_s(i, j) = a_{80(60)}(i, j) - a_{20}(i, j), \quad (2.3)$$

kjer je  $a_{20}(i, j)$  nivo v segmentu ST signala EKG  $j$ -tega srčnega utripa pri točki J+20 ms, izmerjen v točki  $F(i, j) + 60$  ms. Podrobnosti izdelave časovnih vrst vektorjev diagnostičnih značilk v časovnem prostoru so predstavljene v poglavju 6.

## 2.2 Prehodna srčna ishemija

Srčna ishemija sodi med najpogostejše težave srca in ožilja. Nastopi, ko pride do pomanjkljive preskrbe srčne mišice s krvjo ter tako nezadostne oskrbe s kisikom in hranili ter nezadostnim odvajanjem odpadnih produktov mišične aktivnosti [6]. Najpogostejši vzrok za srčno ishemijo so zožanja koronarnih arterij. Srčna ishemija lahko privede do miokardnega infarkta in posledično celo do smrti ter tako lahko pomeni tudi urgentno stanje. Pravočasna ustrezna terapija lahko omeji okvare srčne mišice. Zato je hitra in natančna diagnostika ključna. EKG je pri tem nepogrešljiv, saj se stanja srčne ishemije odražajo v spremenjeni morfologiji – zlasti segmenta ST elektrokardiograma [2].

Segment ST se začne v kolenu J, kjer se signal EKG po depolarizaciji ventriklov srčne mišice v kompleksu QRS praviloma začne izravnovati (slika 2.1). Konča se ob začetku vala T, v katerem se ventrikli repolarizirajo. V segmentu ST je srčno tkivo praviloma električno nevtravno. Če je del tkiva srčne mišice poškodovan zaradi ishemije, je depolarizacija takšnega dela tkiva motena. Zato pride do razlike v električnih potencialih in posledično do električnih tokov na meji med poškodovanim in nepoškodovanim tkivom. To se v EKG odraža v obliki povišanega ali znižanega segmenta ST in v spremenjeni morfologiji segmenta ST. Slednje je odvisno od mesta ishemične poškodbe in posledično smeri električnega toka zaradi poškodbe, relativno na elektrode oziroma os odvoda.

Zato je osrednji predmet našega dela segment ST elektrokardiograma. 24-urni ambulantni posnetki EKG tipično nakazujejo [10] izrazite ( $> 50\mu V$ ) prehodne spremembe v amplitudi funkcije nivoja segmenta ST, izmerjenega 80 ms od kolena J (ali J + 60 ms, če srčna frekvenca presega 120 utripov/min) in prehodne spremembe morfolo-





gije segmenta ST, kar nam predstavlja dogodke prehodnih epizod segmenta ST. Te spremembe povzroča ishemija (prehodne ishemične epizode segmenta ST), kar naj bi avtomatski sistemi za detekcijo ishemije čim učinkoviteje zaznali. Lahko pa jih povzroča tudi množica drugih neishemičnih dogodkov [10], ki jih detektorji ne bi smeli zaznavati. Takšne neishemične spremembe so pogosto zelo podobne pravi ishemiji in so lahko prav tako izrazite ( $> 50\mu V$ ). Slednje tako dodatno otežuje tako "ročno" ekspertno kakor avtomatično zaznavo resničnih ishemičnih epizod segmenta ST. Zanesljivi ST analizatorji bi morali uspešno ločevati med klinično pomembnimi ishemičnimi spremembami in klinično nepomembnimi neishemičnimi dogodki.


Uveljavljeni protokoli za določanje izrazitih prehodnih epizod ishemije temeljijo na spremembi nivoja segmenta ST [10]. Sledijo tipičnemu trikotnemu vzorcu časovnega poteka nivoja segmenta ST ob epizodi prehodne ishemije, ki lahko, ali pa tudi ne, nastopa skupaj s povišano srčno frekvenco. Uveljavljeni so trije standardni protokoli A, B in C (slika 2.2), ki se razlikujejo po minimalnem časovnem razponu in pragu odstopanja nivoja segmenta ST za določitev nastopa ishemije.

Danes večina obstoječih avtomatičnih sistemov neishemičnih dogodkov ne obravnava uspešno, oziroma jih v veliki večini sploh ne poskuša obravnavati. Pokaže se namreč, da tradicionalno merjenje nivoja segmenta ST v eni sami točki v statični lokaciji (J + 80 (60) ms) ni zadostno natančna metoda za pravilno razpoznavanje ishemičnih epizod segmenta ST in razločevanje od neishemičnih sprememb ter tudi za razločevanje med različnimi tipi sprememb segmenta ST.

Objave podatkovne baze Evropskega kardiološkega združenja ST-T Database (ESC DB) [11] in kasneje podatkovne baze dolgotrajnih elektrokardiografskih posnetkov LTST DB [10] kot standardnih referenc na področju merjenja zmogljivosti analizatorjev AEKG so v preteklosti spodbudile hiter razvoj in učinkovito evaluacijo analizatorjev in avtomatskih sistemov za detekcijo prehodnih epizod segmenta ST. Razviti so bili številni zmogljivi avtomatski sistemi. Ti temeljijo na različnih pristopih in tehnikah, med njimi na analizah na osnovi časovnega prostora [12–15], na osnovi transformacije Karhunen in Loèva (KLT) [16, 17], kombinacije tehnik v časovnem prostoru in s transformacijo KLT [18], z uporabo nevronske mreže [19], s kombinacijo transformacije KLT in nevronske mreže [20], z uporabo polinomske aproksimacije [21], s kombinacijo polinomske aproksimacije in analize glavnih komponent [22], z uporabo naivnega Bayesovega klasifikatorja [23] ter z uporabo valčne transformacije in metode podpornih vektorjev [24]. Detektor epizod prehodne srčne ishemije [25], ki deluje

**Funkcija nivoja ST****Referenca ST**

$$\text{Odstopanje ST} = \text{nivo ST} - \text{referenca ST}$$

**Funkcija odstopanja ST**

protokol A:  $V_{\min} = 75\ \mu\text{V}$ ,  $T_{\min} = 30\text{ s}$   
 protokol B:  $V_{\min} = 100\ \mu\text{V}$ ,  $T_{\min} = 30\text{ s}$   
 protokol C:  $V_{\min} = 100\ \mu\text{V}$ ,  $T_{\min} = 60\text{ s}$

Slika 2.2

Uveljavljeni protokoli za določanje izrazitih prehodnih epizod ishemije na osnovi sprememb nivoja segmenta ST v podatkovni bazi LTST DB (vir: [10]).

v realnem času na osnovi diagnostičnih parametrov, pridobljenih v časovnem prostoru, so avtorji nedavno nadgradili [26] z dodatnim korakom klasifikacije detektiranih epizod na razred "pravih" ishemičnih epizod in na razred neishemičnih epizod, ki jih detektor nato dodatno zavrže. Klasifikator deluje na osnovi odločitvenih dreves in prav tako uporablja diagnostične parametre, pridobljene z meritvami v časovnem prostoru. S to metodo so avtorji izboljšali pozitivno napovedljivost iz 57% na 75%, kljub temu pa ta rezultat ne presega rezultatov detektorja [18], ki ne deluje v realnem času.

Problemi učinkovite detekcije neishemičnih epizod in njihovega razločevanja od resničnih ishemičnih dogodkov še niso zadovoljivo rešeni. Potrebne so nove, robustnejše in prilagodljivejše metode, ki bi zaželeno uporabile več informacije o dejanski fiziologiji, ki je porazdeljena preko celotnega segmenta ST elektrokardiograma, ne zgolj v eni sami statični točki. Hkrati bi morale biti takšne metode neobčutljive na spreminjajočo se srčno frekvenco. Ta povzroča ožanje (ali širjenje) segmenta ST v elektrokardiogramu in posledično npr. pomik vala T proti točki merjenja nivoja in tako zaznavo epizod "lažno" povišanega nivoja segmenta ST. Slednje je pomanjkljivost večine današnjih detekcijskih sistemov. Možnost dinamičnega prilagajanja dolžine intervala, ki ga zajamemo z ortogonalno transformacijo (okno transformacije), spreminjajoči se srčni frekvenci, bi lahko znatno izboljšala natančnost zajema diagnostičnih informacij s segmenta ST v elektrokardiogramu. Klasične ortogonalne transformacije namreč predvidevajo konstantno širino okna transformacije.

### *2.3 Epizode odstopanj segmenta ST in njihove morfološke značilnosti*

Segment ST elektrokardiograma je ključnega pomena v klinični diagnostiki srčne ishemije in pri prepoznavanju različnih tipov ishemičnih in "lažnih", neishemičnih, epizod. Epizode odstopanja segmenta ST spremljajo značilne spremembe v morfologiji [10], kot so

- sprememba nivoja,
- sprememba nagiba in
- sprememba ukrivljenosti segmenta ST.

Standardni protokoli A, B in C za določanje ishemije (slika 2.2) temeljijo zgolj na

odstopanju nivoja segmenta ST in ne upoštevajo drugih morfoloških značilnosti, kot denimo nagiba in ukrivljanja segmenta ST.

Za ocenjevanje ukrivljenosti segmenta ST v časovnem prostoru ni uveljavljenih metod. Za ta namen se izkazujejo kot učinkovite nove ortogonalne transformacije segmenta ST, ki jih predstavljamo v nadaljevanju. Hkrati slednje omogočajo tudi natančnejše ocenjevanje sprememb nivoja in nagiba segmenta ST. Zajemanje informacije za ocenjevanje morfoloških lastnosti (celotnega) segmenta ST zgolj v posamičnih točkah signala v časovnem prostoru je namreč izrazito občutljivo na postavitev točk merjenja v dejanskem signalu glede na lokalne naključne artefakte v okolici točke merjenja. Takšni naključni artefakti so denimo posledica motenj, ki jih niso odstranili predhodni procesi filtriranja in izločanja motenj v fazah predobdelave. Merjenje morfoloških lastnosti v točkah časovnega prostora prav tako ne upošteva celotnega poteka oblike segmenta ST kot zapisa poteka dejanskega fiziološkega procesa.

Nadaljnjo težavo predstavlja spreminjajoča se srčna frekvenca, ki neposredno vpliva na dolžino segmenta ST. Merjenje morfoloških lastnosti v posamičnih točkah časovnega signala je namreč prav tako izrazito občutljivo na ne dovolj natančno postavitev točke merjenja. Položaj segmenta ST v elektrokardiogramu srčnega utripa je namreč mogoče določiti le z omejeno natančnostjo na osnovi srčne frekvence in algoritmov za postavitev stabilnih točk v srčnem utripu (točka F in koleno J). Ker povečana srčna frekvenca neposredno vpliva na ožanje segmenta ST, lahko pride do pomika vala T proti točki merjenja. To povzroči nepravilno (povečano) meritev nivoja segmenta ST.

#### *2.4 Ocenjevanje morfologije segmenta ST in ortogonalne transformacije*

Za ocenjevanje oblik (morfologije) elektrokardiograma so bile v kardiologijo uvedene ortogonalne transformacije, ki poskušajo iz vektorjev časovno vzorčenih signalov pomembnih intervalov v elektrokardiogramu, denimo segmenta ST, izluščiti klinično pomembno informacijo v obliki vektorjev morfoloških značilk. Ortogonalna transformacija zniža dimenzionalnost vhodnih podatkov in ohrani koristno informacijo o vhodnem signalu. Podatke predstavi kot koeficiente transformacije oziroma vektor morfoloških značilk v prostoru medsebojno nekoreliranih lastnosti, ki jih predstavljajo ortogonalne bazne funkcije oziroma bazni vektorji. Podrobnosti o ortogonalnih transformacijah so opisane v poglavju 3.

V dosedanji praksi se je na tem področju izkazala za učinkovito transformacija Kar-

hunena in Loèva (KLT). Ta ortogonalna transformacija je teoretično optimalna z vidika minimalne pričakovane srednje kvadratne napake pri inverzni rekonstrukciji vhodnih vzorcev s čim manjšim številom komponent transformiranih vektorjev. Podrobnosti o transformaciji KLT so opisane v poglavju 4. Do sedaj je bila KLT na področjih kardiologije in elektrokardiografije uporabljena za namene ocenjevanja šumov [27], vizualnega določanja akutnih ishemičnih epizod [28], reprezentacije morfologije EKG [27, 29], avtomatske detekcije prehodnih epizod segmenta ST med spremljanjem AE-KG [17, 18], analize intervala ventrikularne repolarizacije (kompleks ST-T) [30–33]. Študija [30], v okviru katere je bila izdelana baza transformacije KLT na osnovi 97.663 z Bazettovo formulo korigiranih vzorcev kompleksov ST-T, pokaže, da so časovne vrste koeficientov transformacije KLT učinkovitejše za spremljanje sprememb v kompleksu ST-T v primerjavi s tradicionalnimi meritvami lastnosti ventrikularne repolarizacije, kot je meritev nivoja segmenta ST. Transformacija KLT je bila uporabljena tudi za namene vizualnega določanja in ekspertnega označevanja prehodnih ishemičnih in neishemičnih epizod segmenta ST v podatkovni bazi elektrokardiografskih posnetkov LTST DB [10] ter avtomatske klasifikacije ishemičnih in neishemičnih srčnih utripov [34–37].


Ocenjevanju oblik z ortogonalnimi transformacijami alternativen pristop je klasifikacija segmentov ST srčnih utripov v razrede pomembnih morfoloških lastnosti. Na osnovi metode prostora meril ukrivljenosti (angl. Curvature Scale Space) in empirično določenih pravil s pragovi [38] klasificira segmente ST posamičnih srčnih utripov v pet razredov: "raven", "nagnjen navzgor", "nagnjen navzdol", "konkaven", "konveksen". Transformacija KLT namreč ne daje jasnih ocen o pomembnih oblikah, kot jih prepozna klinična praksa, temveč njeni koeficienti ocenjujejo le prisotnosti morfologij, ki so najbolj zastopane v učni množici. Prednost te metode v primerjavi s transformacijo KLT je, da oblike, ki jih predstavljajo postavljeni razredi, natančno ustrezajo v klinični praksi prepoznanim pomembnim morfološkim lastnostim. Soroden pristop določanja oblik segmenta ST elektrokardiograma s klasifikacijo na osnovi empirično določenih pravil [39] pa klasificira srčne utripe poleg enakega nabora petih razredov morfologij še v razred normalnih segmentov ST. Še en pristop [40] na osnovi značilk, ki jih pridobi iz časovnega signala EKG, kot so nivo, varianca in nagib segmenta ST, klasificira segmente ST posamičnih srčnih utripov v deset razredov morfologij. Pristop h klasifikaciji segmentov ST glede na njihovo morfologijo, ki so ga razvili [41], temelji na skonstruirani množici referenčnih segmentov ST. Vendar te metode ne omogočajo

ocenjevanja stopnje prisotnosti posamezne morfologije v signalu in ne upoštevajo dejstva, da v praksi srčni utripi sodijo v več tako postavljenih razredov (npr. nagib navzdol z ukrivljanjem).

Poleg transformacije KLT lahko vhodne vektorje časovnih vzorcev transformiramo v vektorje, ki nam bolj organizirano in zgoščeno opišejo podatke o morfologiji vhodnega signala, tudi z drugimi transformacijami – denimo s takšnimi, ki imajo bazo transformacije osnovano na ortogonalnih polinomih. Dosedanja praksa uporabe ortogonalnih polinomov za procesiranje signalov EKG je omejena. Hermitovi polinomi so bili uporabljeni za ocenjevanje značilk EKG [42] in gručenje (angl. clustering) kompleksov QRS [43]. Hermitovi, Legendrovi in Čebiševi ortogonalni polinomi so bili prav tako uporabljeni za filtriranje in reprezentacijo morfologije EKG [44]. Za izločanje morfoloških značilk so bili uporabljeni Čebiševi polinomi prve in druge vrste [45] na sorodnem področju segmenta ST pri laboratorijski miši [46]. Uporaba polinomov, kakršni so tudi Čebiševi ortogonalni polinomi, kjer prvi polinom predstavlja konstantno funkcijo, drugi polinom linearno funkcijo, tretji polinom pa kvadratno funkcijo, namreč obeta pomembno prednost, da bi lahko prve tri dimenzije takšne transformacije nudile neposredno informacijo o prisotnosti najpomembnejših klinično določenih morfoloških lastnosti segmenta ST, kot so njegov nivo, nagib in ukrivljenost [10]. Vendar transformacija segmenta ST na osnovi Čebiševih polinomov prve in druge vrste ni dala zadovoljivih rezultatov. Izkaže se, da ta družina funkcij za tak namen ni najprimernejša zaradi ortogonalnosti polinomov pri nekonstantni utežni funkciji. Slednje v njihovi ortogonalni formi deformira zeleno obliko funkcij Čebiševih polinomov (slika 2.3) in tako poslabša zaznavo klinično prepoznano pomembnih morfoloških lastnosti segmenta ST. Ortogonalnost baznih funkcij je pomembna, da se informacija o preučevanih morfoloških lastnostih ne razprši preko različnih dimenzij transformiranega prostora.

Hkrati smo tudi pri baznih funkcijah KLT za segment ST opazili izrazite podobnosti v njihovih oblikah z nekaterimi družinami ortogonalnih polinomov (še izraziteje pri novih baznih funkcijah na posamičnih odvodih, ki smo jih izdelali v okviru tega dela). To nas je še dodatno motiviralo k oblikovanju ortogonalne transformacije segmenta ST elektrokardiograma na osnovi ortogonalnih polinomov, ki bi odpravila pomanjkljivosti Čebiševih polinomov.

Izkazalo se je, da družina Legendrovih polinomov [47, 48] edinstveno združuje vse iskane lastnosti: ortogonalnost s konstantno utežno funkcijo, podobnost oblik funkcij



Slika 2.3


Grafi prvih treh Čebiševih polinomov prve vrste na intervalu  $[-1, 1]$  (zgoraj, obarvani zeleno) in poleg slednjih (spodaj, obarvani modro) grafi istih polinomov na intervalu  $[-1, 1]$  pomnoženih z utežno funkcijo kot v ortogonalni formi. Razvidno je, da se oblike funkcij znatno spremenijo. Ključne lastnosti, ki bi jih želeli zaznavati, še posebno ukrivljenost, se "razmažejo" preko več baznih funkcij, če bi za osnovo ortogonalne transformacije vzeli takšne polinome.

z "naravnimi" baznimi funkcijami KLT, oblika funkcij začetnih polinomov zastopa tri naštetje diagnostično pomembne lastnosti segmenta ST, kar je razvidno tudi s slike 2.4. Tako smo zasnovali novo diskretno ortogonalno transformacijo segmenta ST na osnovi Legendrovih polinomov (LPT). Predstavitev oblik segmenta ST s takšno matematično osnovano skupino baznih funkcij obeta pomembne prednosti na področjih avtomatske in ročne obdelave signalov EKG.

Bistveno je, da te "čiste" elementarne funkcije kot so

- konstanta (prvi Legendrov polinom),
- linearna funkcija (drugi Legendrov polinom),
- kvadratna funkcija (tretji Legendrov polinom),

hkrati opisujejo klinično pomembne patološke ishemične spremembe v morfologiji,



Slika 2.4

Grafi prvih štirih Legendrovih polinomov na intervalu  $[-1, 1]$ . Z zeleno barvo so označeni prvi trije Legendrovi polinomi, ki nosijo značilnosti klinično pomembnih morfoloških lastnosti segmenta ST elektrokardiograma. Prvi polinom ( $P_0$ ) je konstantna funkcija, drugi polinom ( $P_1$ ) je linearna funkcija, tretji polinom ( $P_2$ ) pa je kvadratna funkcija.

kot jih navaja kardiologija [10]:

- elevacija ali depresija (sprememba nivoja),
- nagib navzgor ali navzdol (sprememba nagiba) in
- ukrivljanje oziroma sprememba ukrivljenosti.


Uporaba Legendrovih polinomov v kardiologiji na področju analize segmenta ST je prvič opisana v našem delu. V dosedanji praksi so bili uporabljeni za kompresijo podatkov celotnega elektrokardiograma (ne posebnih intervalov) [49] ter za namene biometrične identifikacije in avtentikacije [50] na osnovi kompleksa QRS – intervala,



ki v elektrokardiogramu nastopi pred segmentom ST. Podrobnosti o transformaciji LPT so opisane v poglavju 5.

## 2.5 Vpliv spreminjajoče se srčne frekvence na ocenjevanje morfološkega segmenta ST

Spreminjajoča se srčna frekvenca  $h$  znatno vpliva na trajanje pojavov v signalu EKG. Ti kljub spremenjeni časovni dolžini lahko sodijo v povsem enake razrede. Primer takšnega spreminjanja dolžine segmenta ST elektrokardiograma zaradi spreminjajoče se srčne frekvence je ilustriran na sliki 2.5. S spremenjenim trajanjem pojava, ki ga preučujemo, se spreminja tudi časovna dolžina vhodnih vektorjev vzorcev za računalniško analizo z diskretno ortogonalno transformacijo, če vanje pri konstantni frekvenci vzorčenja zajemamo časovne vzorce celotnega preučevanega pojava. Toda diskretna ortogonalna transformacija po definiciji temelji na ortogonalni matriki določene (konstantne) dimenzije. Število časovnih vzorcev, ki sestavljajo vsak vhodni vzorčni vektor (tj. njegova dolžina), se mora ujemati z dimenzijo matrike ortogonalne transformacije. Če pa v vhodne vzorčne vektorje zato zajemamo konstantno število časovnih vzorcev, preuč-




Slika 2.5

Ilustracija pojava širjenja segmenta ST zaradi znižane srčne frekvence  $h$  (nakazano v ozadju, modro) oziroma ožanja segmenta ST zaradi povišane srčne frekvence (rdeče) ter posledično tudi pomika vala T v območje statičnega zajema morfološkega segmenta ST (j do  $j+120$  ms) oziroma proti statični točki merjenja nivoja segmenta ST ( $j+80$  ms). Slednje lahko tako povzroči izrazito napačne meritve nivoja segmenta ST s točkovno meritvijo v časovnem prostoru.


vani pojav enakega razreda, vendar različnega trajanja, pogosto zajamemo nenatančno ali pomanjkljivo – npr. ne v celoti, če je trajanje pojava preseglo dimenzijo (matrike) transformacije, ali pa z dodatnim signalom, ki ni več del pojava, če je bil pojav krajši. To je razvidno iz primera na sliki 2.6, kjer je prikazan EKG srčnega utripa z razmeroma visoko srčno frekvenco 164 utripov v minuti. V zadnjem delu znotraj potemnjeno označenega okna za zajem vzorcev segmenta ST standardne (fiksne) dolžine 120 ms vidimo izrazit element morfologije vala T (obkroženo rdeče). Ta je zaradi časovnega ožanja pri višji srčni frekvenci vstopil v fiksno okno za zajem vzorcev in tako predstavlja izrazito motnjo v zajeti morfologiji segmenta ST. Obraten primer srčnega utripa z nizko srčno frekvenco 28 utripov v minuti prikazuje slika 2.7. Vidimo, da znaten del signala, ki še pripada segmentu ST, ni zajet (označeno poševno črtkano potemnjeno). Pri tem srčnem utripu gre za segment ST s pozitivnim nagibom. V nezajetem delu se nagib še nekoliko okrepi, a te morfologije s takšnimi neprilagodljivimi metodami ne zajamemo.

Na primeru slike 2.7 lahko še posebno opozorimo, da tudi pri povsem enostavnih morfologijah, kot jo opazujemo pri tem srčnem utripu na sliki (zgolj zelo raven signal z nagibom), pri katerem bi sprva sklepali, da zaradi nekoliko preozkega okna zajema vzorcev ne izgubimo veliko, učinek spremenjene dolžine kljub vsemu lahko povzroči znatne motnje. Prikazani srčni utrip s segmentom ST z nagibom je zaradi zmanjšane srčne frekvence daljši in ga zato ne zajamemo v celoti. V zajetem intervalu zato ne pokrijemo celotne razlike v amplitudi (na sliki  $\Delta_2$ ), s katero je opredeljen nagib. Nagib zajetega signala se tudi v vzorčnih vektorjih za ocenjevanje morfologije z ortogonalno transformacijo odraža kot razlika v amplitudah med časovnimi vzorci, ki sestavljajo vzorčni vektor. Zato celo v tem preprostem primeru tako z metodami v časovnem prostoru kot z ortogonalno transformacijo brez prilagajanja srčni frekvenci zaznamo napačno – manjšo razliko v amplitudi (na sliki  $\Delta_1$ ) in manjši nagib, kot ga ima signal v resnici.

Zaradi zajemanja segmentov ST različnega trajanja z vektorjem vzorcev konstantne dolžine prihaja tudi do sprememb v dolžini značilnih morfoloških elementov (oblik), ko njihovo dolžino opredelimo s številom časovnih vzorcev. To z vidika ortogonalne transformacije lahko učinkuje kot izrazita ("lažna") sprememba morfologije. Posledično se lahko informacija o morfologiji zaradi spreminjajoče srčne frekvence "razmaže"



Primer EKG srčnega utripa z razmeroma visoko srčno frekvenco 164 utripov v minuti iz prvega odvoda posnetka s20541 podatkovne baze LTST DB ob času 22:24:28. Nad območjem segmenta ST v elektrokardiogramu srčnega utripa na sliki je označena standardna (fiksna) širina okna 120 ms za zajem vzorcev segmenta ST (potemnjeni interval). V zadnjem delu znotraj označenega okna za zajem vzorcev vidimo izrazit element morfologije, ki pripada valu T (obkroženo rdeče). To predstavlja izrazito močno in jakej morfologiji segmenta ST s takšnim fiksnim oknom.




Primer EKG srčnega utripa z nizko srčno frekvenco 28 utripov v minuti iz prvega odvoda posnetka 520319 iz podatkovne baze LTST DB ob času 13:36:47. Počezno črtniki del potemnejšega intervala na sliki označuje ocenjeni del resničnega obsega segmenta ST, ki ga standardno (fiksno) okno za zajem vzorcev segmenta ST izrine 120 ms ne zajame. Gre za primer segmenta ST s pozitivnim nagibom. V nezajemtem predelu se nagib še nekoliko okrepi. Vendar te morfološke s takšno neprilagodljivo metodo ne zaznamo. Zaradi preozkega zajema vzorcev prav tako ne zaznamo celotne razlike v amplitudi ( $\Delta_2$ ), ki opredeljuje nagib in posledično ocenimo manjšo amplitudno razliko ( $\Delta_1$ ) in manjši nagib analiziranega segmenta ST od resničnega.

preko različnih dimenzij transformiranega prostora. Ti učinki lahko ob spreminjajoči se srčni frekvenci znatno znižajo natančnost ocenjevanja morfologije signalov z ortogonalno transformacijo. Pri tradicionalnih točkovnih meritvah v časovnem prostoru pa lahko spreminjajoča se srčna frekvenca povzroči celo povsem napačne meritve, kot je ilustirano na sliki 2.5. Spreminjajoča se srčna frekvenca in posledično bistveno spreminjanje dolžine segmenta ST tako v sedanjí klinični praksi predstavljata pomembno težavo pri zanesljivem ocenjevanju dejanske oblike segmenta ST in pri nadaljnjih avtomatskih detekcijskih postopkih, kot sta avtomatska detekcija ishemije in razločevanje od "lažnih", neishemičnih, dogodkov.

Današnji algoritmi za avtomatsko detekcijo in analize segmenta ST elektrokardiograma pojave, povezane s spreminjajočo se srčno frekvenco, obvladujejo le zelo omejeno – s prilagajanjem pozicij točkovnih meritev v omejenem številu diskretnih korakov v časovnem prostoru, medtem ko je ocenjevanje morfologije z ortogonalnimi transformacijami v dosedanjih aplikacijah izvedeno le klasično s konstantno širino okna za zajem vhodnih vzorcev. Zato smo ocenili, da bi bilo za pomembnejši korak v napredku pri natančnosti avtomatskih analiz in detekcijskih aplikacij na osnovi segmenta ST elektrokardiograma pomembno razviti rešitev za uporabo diskretne ortogonalne transformacije, katere širino okna zajema vhodnih podatkov bomo lahko dinamično prilagajali v skladu z dodatnim parametrom, kot je srčna frekvenca. Rezultati transformacije – vektorji morfoloških značilk bodo enake dimenzije in medsebojno primerljivi, kljub prilagodljivemu zajemu vhodnih podatkov različnih dolžin.

## *2.6 Izločanje značilk in predstavitev oblik segmenta ST v dolgih elektrokardiogramih*

Ortogonalne transformacije nam omogočijo izločitev klinično pomembnih informacij z njihovo preslikavo v posamične dimenzije prostora transformacije in zmanjšanje dimenzionalnosti preučevanega prostora. Rezultat transformacije posamičnega segmenta ST elektrokardiograma je tako vektor, katerega komponente nosijo informacijo o posamičnih morfoloških lastnostih analiziranega segmenta ST. S pridobljenimi vektorji morfoloških lastnosti segmentov ST zaporednih srčnih utripov v dolgih elektrokardiogramih tvorimo časovne vrste vektorjev morfoloških značilk. Na takšen način dosežemo zmanjšanje kompleksnosti problemskega prostora tako za avtomatsko kot ekspertno "ročno" preučevanje, analize in diagnostiko. Eksperti kardiologi lahko denimo tako transformiran signal pregledujejo na nivoju vizualizacije večurnih trendov



Slika 2.8

Primer vizualizacije triurnih trendov časovnih vrst vektorjev morfoloških značilnik LPT segmenta ST, za posnetek s20421 podatkovne baze LTST DB od časa 04:00 [hh:mm] do časa 07:00. *Od zgoraj navzdol:* ekspertno označene prehodne epizode segmenta ST (ozki pravokotniki); vizualizirane časovne vrste prvih pet koeficientov LPT segmenta ST s pripadajočo Mahalanobisovo razdaljo (navpična os:  $1\sigma/\text{razdelek}$ ). *Spodaj:* Slike srčnih utripov z nekaterimi značilnimi morfologijami ob oznakah A, B in C v časovnih vrstah; pred paralelnim pomikom [04:13;26.176], po paralelnem pomiku [04:43;30.416] in v ekstremu ishemične epizode segmenta ST [06:30;08.056].

izbora klinično najpomembnejših dimenzij transformacije (tipično tri do osem) na enem samem prikazu (primer vidimo na sliki 2.8). Slednje je občutno učinkovitejše in zavoljo človeškega dejavnika (omejena natančnost človeka pri izvajanju velikega števila ponavljajočih se nalog) lahko tudi natančnejše od pregledovanja oblik posamičnih srčnih utripov (v rangi 3000 do 10000 srčnih utripov na uro posnetka EKG). Na to je opozorila že zgodnja študija o vizualnem preiskovanju funkcij signalov EKG, prikazanih v obliki časovnih trendov za retrospektivno ugotavljanje začetkov in koncev epizod segmenta ST [51]. Ta študija je pokazala, da je takšna tehnika učinkovitejša (100% občutljivost in 100% pozitivna napovedljivost) v primerjavi s konzervativnim vizualnim pregledovanjem izvornih signalov EKG (83% občutljivost, 96% pozitivna napovedljivost) in je primerna za kvantitativno ocenjevanje epizod segmenta ST. To nas

je usmerilo k izbiri tehnik transformacij na osnovi ortogonalnih funkcij za produkcijo časovnih vrst vektorjev morfoloških značilk, ki ocenjujejo oblike in diagnostične lastnosti segmenta ST: tradicionalen pristop s Transformacijo Karhunenena in Loèva (KLT) ter nov pristop s Transformacijo na osnovi Legendrovih polinomov (LPT).

## 2.7 Orodja in gradiva

### 2.7.1 Podatkovna baza elektrokardiografskih posnetkov European Society of Cardiology ST-T Database (ESC DB)

Podatkovna baza elektrokardiografskih posnetkov Evropskega kardiološkega združenja ESC DB [11] je bila razvita med leti 1985 in 1991. Glavna motivacija za nastanek podatkovne baze so bile potrebe po kakovostnem viru označenih elektrokardiografskih podatkov kot enotnem okolju za razvoj in merjenje zmogljivosti novih detekcijskih in analizatorskih sistemov za računalniško podprto diagnostiko in analize na osnovi segmenta ST in vala T v elektrokardiogramu. Razvoj podatkovne baze je financirala Evropska skupnost, koordinator projekta pa je bilo Evropsko kardiološko združenje (European Society of Cardiology). Na projektu so sodelovali še Inštitut za klinično fiziologijo iz Pize, Italija (Institute of Clinical Physiology of the National Research Council), univerza Thoraxcenter of Erasmus University iz Roterdama, Nizozemska, in 13 drugih raziskovalnih skupin iz osmih držav. Podatkovna baza ESC DB obsega 90 "ročno" (utrip-za-utripom) ekspertno označenih dvournih posnetkov elektrokardiogramov v dveh odvodih 79 oseb. Posnetki so vzorčeni s frekvenco vzorčenja 250 Hz pri 12-bitni magnitudni ločljivosti, kjer 200 enot AD pretvornika predstavlja 1 mV.

Epizode segmenta ST so bile označene "ročno" (z vizualno ekspertno analizo posamičnih srčnih utripov) z grafičnim pripomočkom, ki je omogočal primerjavo srčnih utripov v signalu s sliko referenčnega srčnega utripa. Slednji je bil vselej izbran v začetnem delu posamičnega posnetka EKG in je služil kot referenca za primerjavo drugih srčnih utripov. Na takšen način je bilo v časovnem prostoru izvedeno ugotavljanje odstopanj morfologije segmentov ST posamičnih srčnih utripov od reference. Tako so bili postavljeni začetki in konci prehodnih epizod odstopanj segmenta ST in med slednjimi tudi točke ekstremov, kjer odstopanje doseže največjo magnitudo. Vsak posnetek je neodvisno označevalo več skupin kardiologov. Morebitne razlike med oznakami so bile nato ustrezno dodatno obravnavane in usklajevane.

### 2.7.2 Podatkovna baza elektrokardiografskih posnetkov Long-term ST Database (LTST DB)

Glavna motivacija za razvoj podatkovne baze dolgotrajnih elektrokardiografskih posnetkov LTST DB [10] je bila dopolnitev podatkovne baze ESC DB s popolnejšim naborom fizioloških pojavov v elektrokardiogramih, kakršnih posnetki v dvournih intervalih ne zajemajo v zadostnih količinah. Slednje je za razvoj in testiranje novih sistemov za avtomatske analize in detekcijo na osnovi EKG ključnega pomena. V bazi ESC DB denimo ni bilo prisotnih neishemičnih dogodkov, kot so počasno lezenje nivoja ST, premiki električne srčne osi in neishemične epizode zaradi povečane srčne frekvence. Označevanje posnetkov ESC DB je bilo izvajano na nivoju posamičnih srčnih utripov z vizualno "ročno" tehniko označevanja. Zato je bilo neizvedljivo obdelati obsežnejše vire podatkov (več kot dve uri za posamični posnetek EKG), ki bi lahko pokrili dovolj velik nabor različnih dogodkov. Za razvoj podatkovne baze LTST DB je bilo tako treba razviti novo modernejše povsem računalniško podprto "polavtomatsko" okolje Semia (SEMI-Automatic [52]) za analize in označevanje posnetkov, s katerim je bilo možno obvladati okvirno desetkrat večjo količino podatkov od podatkovne baze ESC DB. Elektrokardiografski posnetki podatkovne baze LTST DB tako v povprečju obsegajo 24 ur v dveh ali treh odvodih.

Razvoj podatkovne baze LTST DB se je začel v letu 1995. V letu 1997 je projekt financiralo podjetje Medtronic Inc. (ZDA), dve leti kasneje (1999) pa tudi podjetje Zymed Inc. (ZDA). Projekt se je vodil na Fakulteti za računalništvo in informatiko Univerze v Ljubljani. K projektu so nato pristopile še druge raziskovalne skupine in organizacije: Massachusettski inštitut za tehnologijo (MIT), Beth Israel Deaconess Medical Center (Boston, ZDA), Institute of Clinical Physiology of the National Research Council (Piza, Italija), Univerzitetni klinični Center Ljubljana.

Končna različica podatkovne baze LTST DB vsebuje 86 izbranih klinično pomembnih označenih in predobdelanih posnetkov EKG v dveh ali treh odvodih 80 različnih oseb. Prvič je bila baza objavljena v letu 2002 na osrednjem spletnem portalu za podatkovne baze označenih fizioloških posnetkov Physionet (<http://www.physionet.org/physiobank/database/ltstdb/>) [53] kot ena izmed temeljnih podatkovnih baz fizioloških posnetkov na področju EKG (tj. "Class 1; core"). Fakulteta za računalništvo in informatiko je nepridobitno distribuirala podatkovno bazo. Ta vsebuje tudi nov protokol, ki vključuje časovno spremenljiv ničelni referenčni nivo segmenta ST. Od leta

2007 je podatkovna baza v celoti prosto dostopna na sistemu Physionet. Podatkovna baza se redno posodablja z različnimi novimi fiziološkimi podatki. Tako smo tudi del rezultatov predstavljenega dela (časovne vrste vektorjev morfoloških značilk KLT in LPT brez dinamičnega prilagajanja srčni frekvenci, pridobljene za vse elektrokardiografske posnetke LTST DB) že uspešno objavili v okviru te podatkovne baze na sistemu Physionet.

Posamični elektrokardiografski posnetki LTST DB obsegajo med 19 in 48 ur eksperimentalno označenih signalov EKG. Vseh 86 posnetkov tako skupno vsebuje 8.897.780 srčnih utripov. Posnetki so bili skladno z ESC DB vzorčeni s frekvenco vzorčenja 250 Hz pri 12-bitni magnitudni ločljivosti, kjer 200 enot AD pretvornika predstavlja 1 mV. V nasprotju z ESC DB, kjer so bili posnetki označeni "ročno" z vizualno analizo, so označevalci LTST DB zaradi velikega obsega podatkov uporabljali avtomatizirano (računalniško) obdelavo, ki so jo naknadno verificirali eksperti kardiologi. Stabilne referenčne točke (F) v kompleksu QRS srčnih utripov so bile določene avtomatično z detektorjem aritmij ARISTOTLE [54]. Avtomatično je bil določen tudi izoelektrični nivo kot sredina najbolj ravnega intervala med točkama P in Q levo od stabilne referenčne točke (F), ki jo je postavil ARISTOTLE. Za položaj kolena J je bila fiksno postavljena točka 40 ms za stabilno referenčno točko (FP+40 ms). Tako pripravljene podatke so zatem "ročno" in "polavtomatsko" pregledali eksperti in po potrebi so bili popravljeni oziroma natančneje nastavljeni. Kolena J so bila nato še "ročno" označena.

Na osnovi tako izboljšanih podatkov so bila nato ponovno izračunana odstopanja nivoja segmenta ST pri J+80(60) ms. Časovna vrsta nivoja segmenta ST je bila pridobljena kot odmik signala EKG od izoelektričnega nivoja v točki 80 ms naprej od kolena J v posameznih srčnih utripih, če je bila srčna frekvenca ( $h$ ) manjša od 100 utripov v minuti, oziroma  $J+72$  ms za  $100 \leq h < 110$ ,  $J+64$  ms za  $110 \leq h < 120$ ,  $J+60$  ms za  $h \geq 120$ . Merila za označevanje epizod odstopanja nivoja segmenta ST so v podatkovni bazi LTST DB definirana, kot prikazuje slika 2.2. Definirani so trije protokoli (A, B in C) za določitev epizod odstopanj segmenta ST v skladu z naslednjimi pravili:

1. Odstopanje je izrazito, če v intervalu vsaj 30 s (protokol A in B) oziroma 60 s (protokol C) presega  $75 \mu V$  (protokol A) oziroma  $100 \mu V$  (protokol B in C).
2. Kot epizoda se označi okolica izrazitega odstopanja, kjer vrednost le-tega prvič preseže  $50 \mu V$ .



3. Minimalni čas med dvema epizodama naj bo 30 s, ko je odstopanje nižje od  $50 \mu\text{V}$ .

Ker so v EKG pogosto prisotni počasni neishemični premiki v nivoju ST, LTST DB zgornje označevalne protokole dopolnjuje s postopkom označevanja prilagodljive referenčne poti nivoja ST. Ta se pred uporabo meril po opisanih protokolih za določanje epizod odšteje od funkcije nivoja segmenta ST. Tako dobimo t. i. funkcijo odstopanja (ST deviacija), ki je nato osnova za določanje oznak.

Skladno s tremi protokoli A, B in C so v LTST DB pripravljene tri serije oznak. Protokol A je nekoliko bolj občutljiv, protokol B je primerljiv z ESC DB, protokol C pa je nekoliko bolj selektiven. V nadaljevanju, kjer ni označeno drugače, bomo uporabljali protokol B.

V postopku postavljanja oznak so označevalci podobno kot pri ESC DB najprej določili referenčni srčni utrip v bližini začetka posamičnega posnetka LTST DB (tj. globalna referenca). Ta je bil izbran na mestu, kjer je bil nivo segmenta ST vsaj 300 sekund stabilen (tj. bazalni interval). Zatem so po opisanem postopku s pomočjo orodja Semia "polavtomatsko" z občasnimi "ročnimi" posegi sledili morfologiji signala EKG in funkciji nivoja segmenta ST ter na osnovi izmerjenega nivoja segmenta ST in morfoloških informacij postavljali t. i. lokalne reference nivoja segmenta ST tako, da so te sledile neishemičnim (ali ne dovolj izrazitim) premikom v nivoju segmenta ST ter presecale funkcijo nivoja segmenta ST v intervalih, ki so jih prepoznali kot ishemične. Tako je bila postavljena t. i. referenčna pot (referenčna funkcija) nivoja segmenta ST, ki je bila nato odšteta od funkcije nivoja segmenta ST. Nad tako pridobljeno funkcijo odstopanja nivoja segmenta ST je nato orodje Semia avtomatsko apliciralo tri predstavljenе označevalne protokole A, B in C.

### *2.7.3 Okolje za delo s fiziološkimi signali Waveform Database*

Med razvojem baze fizioloških signalov MIT-BIH [55] so bili razviti tudi obsežno razvojno ogrodje in analitsko okolje ter nabor orodij za obdelavo signalov s skupnim imenom DB Software Package. To je bilo nato preneseno pod odprtokodno licenco GPL (General Public License) in preimenovano v WFDB Software Package (skrajšano WFDB) [56]. Okolje WFDB, v današnji deseti različici, se je uveljavilo kot standard za zapisovanje, označevanje, obdelavo in analiziranje fizioloških signalov.

Nabor orodij in razvojno ogrodje WFDB nudi:

- prikaz in pregledovanje signalov in spremljajočih funkcij ter oznak,
- obdelavo in manipulacijo signalov,
- knjižnice za razvoj programske opreme za obdelavo signalov v formatih WFDB,
- že izdelane analitske aplikacije,
- dokumentacijo, priročnike in definicije formatov za zapis signalov in spremljajočih podatkov.

Pri izvedbi tega dela smo poleg lastno razvitih orodij za prikaz in pregledovanje signalov uporabljali tudi orodje WFDB Wave in spletno različico LightWave. Omogoča prikazovanje, pregledovanje in navigacijo po signalih EKG ter njihovih oznakah. Ne omogoča pa medsebojne primerjave signalov, analize trendov časovnih vrst vektorjev morfoloških značilk, izdelave statističnih analiz in prikazovanja nekaterih drugih funkcij, ki so pri LTST DB zapisane v besedilnih datotekah. Zato je bilo treba razviti tudi lastna orodja, orodje WAVE pa nam je služilo kot referenca, s katero smo preverili točnost delovanja lastnih aplikacij.

Za dostop do tistih podatkovnih zbirk baze LTST DB, ki so zapisane v formatih WFDB, lastna razvita orodja temeljijo na ogrodju knjižnic WFDB Library. Te so razvite v jeziku C na operacijskem sistemu Unix in so, tako navajajo avtorji [56], prenosljive v številna razvojna okolja na različnih operacijskih sistemih in procesorskih arhitekturah. WFDB Library vsebuje popoln nabor funkcij in definicij podatkovnih struktur za delo s fiziološkimi signali in spremljajočimi podatki, zapisanimi v formatih WFDB.

*Analiza signalov EKG s  
prilagodljivimi ortogonalnimi  
transformacijami*

Zamislimo si analitski sistem, v katerega vstopajo časovni vzorci  $g[n]$  vhodnega signala, vzorčeni s konstantno frekvenco vzorčenja. V vhodnem signalu občasno nastopi pojav, katerega lastnosti bi želeli oceniti za vsako njegovo pojavitev. Preiskovani pojav je posledica nekega (fiziološkega) procesa ali mehanizma, ki se občasno začne, poteka in zaključi v izvoru vhodnega signala ter med svojim potekom značilno spremeni vhodni signal. A četudi je sprememba, ki jo preučevani pojav povzroči v vhodnem signalu, značilna za ta pojav, po čemer ravno prepoznamo nastop pojava, med različnimi pojavitvami tega pojava prihaja do bolj ali manj izrazitih razlik. Nekatere izmed teh razlik so značilne za posamične razrede pojavitev preiskovanega pojava in lahko pokažejo na različne razrede procesov v (fiziološkem) izvoru vhodnega signala. Zaznavanje teh značilnosti in analiza procesov v ozadju različnih razredov pojava so naš cilj. Primer takšnega fiziološkega signala je denimo signal EKG, pojav, ki bi ga želeli analizirati, pa segment ST elektrokardiograma, ki se pojavi v vsakem srčnem utripu.

Če imamo zanesljivo metodo za določitev začetka vsake pojavitve preiskovanega pojava v vhodnem signalu in nam  $s_m$  predstavlja tisti indeks  $n = s_m$ , pri katerem se v vzorčenem vhodnem signalu  $g[n]$  začne  $m$ -ta pojavitev pojava, lahko iz vhodnega signala zajemamo vektorje vzorcev  $\mathbf{x}_m$ , katerih komponente sestavlja  $M$  časovnih vzorcev,

$$\mathbf{x}_m = g[s_m + k] ; \quad k = 0, 1, 2, \dots, M - 1 , \quad (3.1)$$

kjer  $M$  ustreza pričakovanemu trajanju pojava, izraženem v številu časovnih vzorcev pri izbrani frekvenci vzorčenja in pomeni dolžino vzorčnih vektorjev  $\mathbf{x}_m$ .

Pri tako zajetih pojavih nam učinkovito analitsko orodje predstavljajo diskretne ortogonalne transformacije. V vzorčenih časovnih signalih – tj. signalih, ki so vzorčeni v njihovem časovnem poteku v enakih zaporednih časovnih intervalih, pravimo jim tudi signali v časovnem prostoru – so namreč preučevani procesi pogosto slabo zaznavni. Ortogonalne transformacije nam vhodne časovne signale spremenijo (transformirajo) v vektorje značilk. Tako transformirane vektorje je moč poenostaviti (zmanjšati dimenzijo transformiranega prostora), lastnosti, ki so predmet analize, pa v novi obliki kljub poenostavitvi postanejo izrazitejše oziroma boljše zaznavne.

Tu opozorimo, da pri signalih, zajetih iz realnega sveta, dejansko trajanje vsake pojavitve preiskovanega pojava pogosto ni natančno enako v naprej določeni konstantni dolžini  $M$ , kot po definiciji (v nadaljevanju) zahteva klasična ortogo-

nalna transformacija. Vzorčni vektor  $\mathbf{x}_m$  konstantne dolžine  $M$  tako bodisi ne vsebuje pojava v celoti ali pa vsebuje poleg pojava še del preostalega signala, ki ni značilen za preiskovani pojav in pomeni motnjo. Pri analizi fizioloških signalov, denimo, pogosto naletimo na procese enakega kliničnega pomena, le drugačnega trajanja. V takem primeru bodo dolžine značilnih morfoloških elementov pojava (značilne oblike grafa časovnega poteka pojava) zaradi različnega trajanja ob enaki frekvenci vzorčenja spremenjene tudi, ko jih opredelimo s številom časovnih vzorcev. To povzroči razpršitev informacije v ortogonalni transformaciji in lahko znatno okvari natančnost zaznavanja značilnosti. Rešitvi te pomembne težave se bomo posvetili v poglavju 3.4.

### 3.1 Diskretna ortogonalna transformacija

Povzeto po [3, 7, 57–59].

Diskretna ortogonalna transformacija je linearna preslikava, ki nam vhodni vzorčni vektor dolžine  $M$  vzorcev preslika v vektor značilk dolžine  $M$  koeficientov v prostoru, katerega bazo tvori izbrani nabor  $M$  medsebojno ortogonalnih baznih vektorjev.

Vsak poljuben vektor  $\mathbf{x}$  lahko izrazimo kot linearno kombinacijo  $M$  poljubnih linearno neodvisnih vektorjev  $\mathbf{v}_i$ :

$$\mathbf{x} = \sum_{i=1}^M \mathbf{v}_i c_i . \quad (3.2)$$

Vektorjem  $\mathbf{v}_1, \mathbf{v}_2, \mathbf{v}_3, \dots, \mathbf{v}_M$  pravimo bazni vektorji. Koeficienti  $c_1, c_2, c_3, \dots, c_M$  določajo vektor  $\mathbf{x}$  relativno glede na bazne vektorje  $\mathbf{v}_i$ .

Enačbo (3.2) lahko zapišemo v matrični obliki:

$$\mathbf{x} = \Phi \mathbf{y} , \quad (3.3)$$

kjer je  $\Phi$  matrika, katere stolpci vsebujejo bazne vektorje  $\mathbf{v}_i$ , komponente vektorja  $\mathbf{y}$  pa so vrednosti koeficientov  $c_1, c_2, c_3, \dots, c_M$ . Če ima matrika  $\Phi$  inverz  $\Phi^{-1}$ , lahko

izrazimo

$$\mathbf{y} = \Phi^{-1} \mathbf{x} . \quad (3.4)$$

Matrika  $\Phi^{-1}$  je tako linearna preslikava, ki preslika poljuben vektor  $\mathbf{x}$  iz izhodiščnega prostora v prostor baze  $\mathbf{v}_1, \mathbf{v}_2, \mathbf{v}_3, \dots, \mathbf{v}_M$ , v katerem je  $\mathbf{x}$  predstavljen s koeficienti  $c_i$  oziroma komponentami vektorja  $\mathbf{y}$ . Matrika  $\Phi$  izvede obratno linearno preslikavo, ki iz vektorja koeficientov  $c_i$  (tj. vektorja  $\mathbf{y}$ ) restavrira izvorni vektor  $\mathbf{x}$ .

Diskretna ortogonalna transformacija (v nadaljevanju: ortogonalna transformacija) je linearna preslikava  $\mathbf{T} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ , ki ohranja ortogonalnost in skalarni produkt [57]. Če je  $\Phi$  matrika ortogonalne transformacije, jo lahko zapišemo kot kvadratno matriko

$$\Phi = [\Phi_{ij}] ; \quad i, j = 1, 2, 3, \dots, M , \quad (3.5)$$

kjer je  $M$  dimenzija transformacije, stolpci matrike  $\Phi_i$  oziroma bazni vektorji pa so medsebojno ortogonalni. Zadoščajo relaciji ortogonalnosti:

$$\Phi_i^\top \Phi_j = \delta_{ij} ; \quad i, j = 1, 2, 3, \dots, M , \quad (3.6)$$

kjer je  $\delta_{ij}$  Kroneckerjeva delta funkcija:

$$\delta_{ij} = \begin{cases} 1, & \text{za } i = j , \\ 0, & \text{za } i \neq j . \end{cases} \quad (3.7)$$

Na ravni celotne matrike  $\Phi$  lahko to povzamemo v:

$$\Phi^\top \Phi = [\delta_{ij}] = \mathbf{I} ; \quad i, j = 1, 2, 3, \dots, M , \quad (3.8)$$

kjer  $\mathbf{I}$  predstavlja enotsko matriko. Matriki, ki zadošča temu pogoju, pravimo ortogonalna matrika. Za vsako ortogonalno matriko tako velja

$$1 = |\Phi^\top \Phi| = |\Phi^\top| |\Phi| = |\Phi|^2 \quad (3.9)$$

in zatorej

$$|\Phi| = \pm 1 . \quad (3.10)$$

Opomba: Ravni oklepaji v zgornjih enačbah pomenijo matrično determinanto in jih bralec ne sme zamešati z absolutno vrednostjo realnega števila.

Ker je determinanta ortogonalne matrike  $\Phi$  različna od 0 (enačba 3.10), obstaja njena inverzna matrika. Iz enačbe (3.8) izhaja, da jo izrazimo kot transponirano matriko:

$$\Phi^{-1} = \Phi^{\top} . \quad (3.11)$$

$\Phi^{\top}$  predstavlja inverz ortogonalne transformacije  $\Phi$  in je prav tako ortogonalna transformacija. Formulo (3.4) lahko tako izrazimo tudi kot

$$\mathbf{y} = \Phi^{\top} \mathbf{x} . \quad (3.12)$$

### 3.2 Ortogonalna transformacija kot analitsko orodje

Če nam  $\mathbf{x}_m$  predstavlja vzorčni vektor, ki ga po (3.1) sestavlja  $M$  časovnih vzorcev  $m$ -te pojavitve preučevanega pojava iz vzorčenega vhodnega signala, ga lahko tako z ortogonalno transformacijo  $\Phi^{\top}$  dimenzije  $M$  transformiramo v vektor značilk  $\mathbf{y}_m$  dolžine  $M$  koeficientov:

$$\mathbf{y}_m = \Phi^{\top} \mathbf{x}_m . \quad (3.13)$$

Posamične komponente vektorja  $\mathbf{y}_m$  oziroma koeficienti transformacije, tj.  $\mathbf{y}_m = (c_{m1}, c_{m2}, c_{m3}, \dots, c_{mM})$ , izražajo transformacijo vektorja  $\mathbf{x}_m$  kot njegovo magnitudo v posamičnih dimenzijah prostora transformacije. Koeficienti ustrezajo pripadajočim baznim vektorjem  $\Phi_j$ . Zato pravimo tudi, da vektor  $\mathbf{x}_m$  razstavimo na komponente baznih vektorjev, kjer vsak posamični koeficient transformacije  $c_{mj}$  predstavlja magnitudo pripadajočega baznega vektorja v vektorju  $\mathbf{x}_m$ .

Ortogonalno transformacijo lahko tako uporabimo kot analitsko orodje. Matriko ortogonalne transformacije je možno skonstruirati na takšen način, da za bazne vektorje poiščemo medsebojno ortogonalne diskretne funkcije  $f_j(i)$  z določenimi poznanimi lastnostmi, ki nas zanimajo:

$$\Phi_{ij} = f_j(i) \quad ; \quad i, j = 1, 2, 3, \dots, M . \quad (3.14)$$

Take bazne vektorje bomo zato imenovali tudi bazne funkcije. Bazne funkcije morajo

zadoščati relaciji ortogonalnosti:

$$\sum_{i=1}^M f_m(i) f_n(i) = K_m \delta_{mn} \quad ; \quad m, n = 1, 2, 3, \dots, M. \quad (3.15)$$

Če za vhodni vektor vzamemo  $M$  (časovnih) vzorcev nekega preučevanega pojava, katerega lastnosti bi želeli določiti, nam transformacija  $\Phi^\top$  izvede analizo vhodnega vzorčnega vektorja glede na lastnosti baznih funkcij. Posamični koeficienti takšne transformacije vhodnega vzorčnega vektorja predstavljajo podatek o zastopanosti pripadajočih baznih funkcij z lastnostmi, ki nas zanimajo, v preučevanem vhodnem pojavu. Če nam preučevani proces ustvarja vhodne vektorje v rednih časovnih intervalih, lahko koeficiente transformacije uredimo v časovne vrste za vsak posamični koeficient, oziroma časovne vrste vektorjev, katerih komponente vsebujejo koeficiente transformacije. Časovni potek, ki ga lahko prikaže takšna časovna vrsta, bodisi vizualizirana v obliki časovnega grafa bodisi kot gradivo za nadaljnjo računalniško obdelavo, pogosto nosi dodatno informacijo o dinamiki opazovanih procesov.

Kadar tako pridobljene koeficiente transformacije uporabimo za nadaljnjo računalniško analizo vhodnih vzorcev (klasifikacijo), jih imenujemo tudi značilke, časovne vrste vektorjev, katere tvorijo, pa časovne vrste vektorjev značilk.

### 3.3 Zmanjšanje dimenzije transformiranega prostora

Pomembna lastnost diskretne ortogonalne transformacije je možnost izločanja najpomembnejših značilk oziroma izbire podmnožice tistih koeficientov transformacije, za katere pričakujemo, da bodo dali najboljše rezultate pri izvajanih analizah (denimo pri klasifikaciji med določenimi razredi vhodnih vzorcev). S tem zmanjšamo dimenzijo problemskega prostora, poenostavimo analitske procese tako z vidikov računske zahtevnosti kot razumljivosti rezultatov in lahko tudi izboljšamo njihovo natančnost. Z dobro izbiro podmnožice značilk namreč lahko zajamemo dovolj velik delež za preučevane pojave pomembne informacije že iz transformiranih vhodnih vzorcev s tako zmanjšano dimenzijo. Hkrati pa na takšen način zavržemo informacije, ki za preučevane pojave niso pomembne in bi učinkovale kot motnje. Pogosto je zmanjšanje dimenzije transformiranega prostora pomembno tudi z vidikov tehnične optimizacije. Če denimo analiziramo večje količine podatkov, kot so dolgotrajni posnetki EKG, so takšne analize lahko tako časovno kot tudi prostorsko zahtevne. Zato je smotno



izvajati operacije (tj. tako izračun same transformacije kot tudi nadaljnje analize rezultatov transformacije) le nad izbranimi dimenzijami transformiranega prostora, ki so za takšno analizo pomembne.

Za preučevanje lastnosti, ki najizraziteje kažejo na razlike med vzorci v vhodnih populacijah, lahko izberemo prvih  $N$  koeficientov transformacije  $c_i$ , ki imajo na neki dovolj reprezentativni predhodni učni množici največje standardne deviacije  $\sigma_i$ :

$$\sigma_i = \sqrt{\frac{1}{K} \sum_{j=1}^K (c_{ij} - \mu_i)^2} , \quad (3.16)$$

kjer je  $\mu_i$  srednja vrednost koeficienta  $c_i$ :

$$\mu_i = \frac{1}{K} \sum_{j=1}^K c_{ij} . \quad (3.17)$$

Toda ob zmanjšanju dimenzije transformiranega prostora pride do določene izgube izvirnega signala. To se kaže kot napaka pri rekonstrukciji vhodnega vzorčnega vektorja  $\mathbf{x}$  v aproksimacijo  $\hat{\mathbf{x}}$  na osnovi vektorja značilk prostora zmanjšane dimenzije z inverzno transformacijo. Če tako vzorčni vektor z inverzno transformacijo rekonstruiramo zgolj na osnovi podmnožice izbranih koeficientov  $c_i$ :

$$\hat{\mathbf{x}} = \sum_{i \in \mathcal{S}} \mathbf{v}_i c_i , \quad (3.18)$$

kjer  $\mathcal{S}$  predstavlja množico indeksov koeficientov in pripadajočih baznih vektorjev, ki tvorijo izbrani prostor zmanjšane dimenzije,  $\mathbf{v}_i$  pa so bazni vektorji prostora zmanjšane dimenzije, pri takšni rekonstrukciji pride do napake. Ta se odraža kot odstopanje aproksimiranega vektorja vzorca  $\hat{\mathbf{x}}$  glede na izvorni vhodni vektor vzorca  $\mathbf{x}$  [3]. Slednje lahko določimo kot srednjo kvadratno napako pri vhodnem vektorju vzorca  $\mathbf{x}$  dolžine  $M$  časovnih vzorcev:

$$E\{|\mathbf{x} - \hat{\mathbf{x}}|^2\} = \frac{1}{M} \sum_{i=1}^M (\mathbf{x}_i - \hat{\mathbf{x}}_i)^2 , \quad (3.19)$$

in skupno srednjo kvadratno napako v populaciji vhodnih vzorcev  $\mathbf{x}_l$ :

$$e^2(\mathcal{S}) = \sum_{l=1}^L p_l E\{|\mathbf{x}_l - \hat{\mathbf{x}}_l|^2\} , \quad (3.20)$$

kjer  $\mathcal{S}$  predstavlja množico indeksov baznih vektorjev in pripadajočih koeficientov, ki smo jih izbrali za aproksimacijo vhodnega vektorja,  $L$  pomeni število vzorcev v vhodni populaciji,  $p_l$  pa predstavlja verjetnost oziroma relativno frekvenco vzorca  $\mathbf{x}_l$  v vhodni populaciji.

Če želimo sestaviti čim manjši nabor koeficientov transformacije, ki zajema čim več informacije o pričakovanih vhodnih signalih, je za tak izbor pomembno, da bo vsak naslednji dodani koeficient v množico  $\mathcal{S}$  prinesel čim večje zmanjšanje srednje kvadratne napake  $e^2(\mathcal{S})$  dane (primerno reprezentativne) učne populacije  $\mathbf{x}_l$ .

Dobra metoda za določitev zmanjšane dimenzije transformiranega prostora je denimo izbira koeficientov na osnovi njihovih standardnih deviacij v učni množici (formula 3.16), ki jih po požrešni metodi (najprej koeficient z največjo standardno deviacijo) dodajamo v množico  $\mathcal{S}$ . Na tak način v pogostih aplikacijah pride do hitrega padca napake  $e^2(\mathcal{S})$  v začetnih korakih požrešnega algoritma. Z naraščajočim številom dodanih koeficientov v  $\mathcal{S}$  pa se zmanjševanje napake upočasni. Tako lahko določimo prag zmanjšanja napake ob naslednjem dodanem koeficientu v  $\mathcal{S}$ , pri katerem empirično presodimo, da izračunana velikost prispevka k zmanjšanju napake za preučevane pojave ni več pomembna. Alternativno lahko določimo tudi prag velikosti izračunane skupne preostale napake  $e^2(\mathcal{S})$ , za katero prav tako empirično presodimo, da je dovolj majhna za preučevane pojave. Algoritem požrešnega dodajanja koeficientov v  $\mathcal{S}$  ob preseženem pragu ustavimo.

Zmanjšano dimenzijo transformiranega prostora lahko za potrebe neke specifične analize postavimo tudi eksperimentalno na osnovi optimizacije neke izbrane mere učinkovitosti  $A(\mathcal{S})$ , te analize nad učno množico z različnimi izbirami značilk  $\mathcal{S}$  do določenega praga učinkovitosti. Takšna izbira je lahko bolj optimalna in bolj prilagojena specifični analizi. Možna strategija je iskanje bodisi najboljšega izbora bodisi prvega izbora, ki dosega postavljene pragove učinkovitosti, v vrsti izborov  $\mathcal{S}$ , urejenih po naraščajočih  $A(\mathcal{S})$ . Izbore tvorimo po požrešni metodi z dodajanjem tistih značilk v  $\mathcal{S}$ , ki prinesejo največje povečanje  $A(\mathcal{S})$ . Manj zahtevna strategija pa je iskanje bodisi najboljšega bodisi prvega izbora, ki dosega postavljene pragove mere učinkovitosti  $A(\mathcal{S})$ ,

v vrsti izborov  $\mathcal{S}$ , ki jih tvorimo s požrešnim izbiranjem značilk z največjo standardno deviacijo v učni množici. Določanje  $\mathcal{S}$ , urejenih po naraščajočih  $A(\mathcal{S})$ , pri prvi strategiji, je namreč računsko zahtevnejše, saj je treba na vsakem koraku požrešnega algoritma nad celotno učno populacijo izvesti nove izračune  $A(\mathcal{S})$  za  $\mathcal{S}$  z dodano vsako izmed še neuporabljenih značilk. Pričakovati pa je velik obseg podatkov učne populacije, saj želimo njeno reprezentativnost.

Tako pridobimo izbiro koeficientov za zmanjšano dimenzijo transformiranega prostora, od katere lahko pričakujemo zajemanje informacij o pomembnih procesih v izvoru vhodnih signalov z želeno natančnostjo kljub manjšemu številu značilk.

Z ortogonalnimi transformacijami lahko tako analiziramo denimo fiziološke signale. V transformacijo v takšnem primeru vstopajo vhodni vektorji, ki vsebujejo vzorčene intervale časovnega poteka preiskovanih signalov, bazne funkcije pa predstavljajo posamične preiskovane lastnosti analiziranih vhodnih signalov. Če nas zanimajo morfološke lastnosti preiskovanih vhodnih signalov, lahko za bazo transformacije izberemo bazne funkcije z oblikami osnovnih značilnih morfologij, ki jih pričakujemo v vhodnih signalih. Če takšne bazne funkcije zastopajo najizrazitejše lastnosti preučevanih signalov in se hkrati med seboj tudi dobro ločijo glede na zastopanje različnih procesov v izvoru preučevanih signalov, lahko od koeficientov takih baznih funkcij pričakujemo velike prispevke k zmanjšanju srednje kvadratne napake in velike standardne deviacije njihovih časovnih vrst. Analitske lastnosti ortogonalne transformacije so tako ključno odvisne od izbire njene baze.

### 3.4 *Dinamično prilagajanje dolžine vzorčnih vektorjev*

Kadar bi želeli analizirati neki pojav, ki se pojavlja v preučevanem izvoru signala, ki ga zajemamo z vzorčenjem s konstantno frekvenco vzorčenja, se nam lahko zgodi, da trajanje pojava, ki nas zanima, ni vselej enako. Kljub temu pa je pojav vselej posledica enakega (fiziološkega) procesa v izvoru signala, le da ta poteka s spremenjeno hitrostjo. Primer takšnega pojava je denimo potek srčnega utripa v signalu EKG (slika 1.3.A), kjer lahko opazujemo ožanje in širjenje slik elektrokardiograma posamičnih srčnih utripov ob spreminjanju srčnih frekvenc. Učinek se prenese tudi na posamične intervale in segmente znotraj poteka EKG srčnega utripa, kakršen je tudi segment ST (slike 2.5, 2.6, 2.7). Trajanje poteka srčnega utripa (in segmenta ST) je namreč odvisno od srčne frekvence. Hitrejše, kot je bitje srca, hitrejši je potek srčnega utripa. Posledica tega je, da pomembne intervale elektrokardiograma srčnega utripa pri posamičnih srčnih utri-

pih zajemamo z različnim številom časovnih vzorcev. A ker gre kljub temu za pojavitve istih fizioloških pojavov z enakimi procesi v ozadju, bi jih želeli preučevati na enak način. Pridobljene podatke o lastnostih posamičnih pojavitev pojava bi želeli medsebojno primerjati in skupno analizirati, kljub različni dolžini vhodnih podatkov.

Če pojavitve preiskovanega pojava iz vhodnega signala zajemamo z vzorčnimi vektorji konstantne dolžine, se nam ob takšni spremenljivosti lahko v vhodnih podatkih pojavi še del signala, ki ni značilen za preiskovani pojav (slika 2.6), ali pa preiskovanega pojava ne zajamemo v celoti, če ta traja dlje od konstantne časovne dolžine vzorčnega vektorja (slika 2.7). S spreminjajočo časovno dolžino preiskovanega pojava pa se spreminjajo tudi dolžine samih značilnih elementov njegove morfologije, ko jih opredelimo s številom časovnih vzorcev ob konstantni frekvenci vzorčenja. To z vidika ortogonalne transformacije pomeni "lažno" spremembo morfologije in povzroči razpršitev informacije v ortogonalni transformaciji ter lahko znatno zniža natančnost zaznavanja značilnosti, ki jih želimo preučevati s transformacijo (poglavje 2.5).

Če imamo metodo, s katero lahko zanesljivo ugotavljamo spreminjajoče se časovno trajanje pojava, ki ga želimo preučevati, oziroma, če lahko natančno določamo začetke in konce pojavitev preiskovanega pojava v vhodnem signalu, lahko kljub temu tvorimo časovno vrsto vhodnih vektorjev, ki vsebujejo vzorce časovnega poteka posamičnih pojavitev preiskovanega pojava natančno in v celoti. Vendar pa bodo tako tvorjeni vhodni vektorji medsebojno različnih dolžin, če dolžino opredelimo kot število časovnih vzorcev, ki sestavljajo vhodni vzorčni vektor. Toda vektorjev različnih dolžin ni mogoče analizirati z ortogonalno transformacijo enotne dimenzije. Dolžina vhodnega vzorčnega vektorja mora namreč ustrezati dimenziji matrike transformacije. Zato moramo postopek transformacije za uspešno analizo tovrstnih pojavov dopolniti s predhodnim prevzorčenjem vhodnega vzorčnega vektorja na izbrano enotno dolžino.

Naj bo  $r_m$  neki dodatni parameter (pri signalih EKG je to lahko srčna frekvenca), ki vstopa v naš analitski sistem skupaj z vzorčenim vhodnim signalom  $g[n]$  ob vsaki  $m$ -ti pojavitvi preiskovanega pojava v  $g[n]$ .  $s_m$  pa naj bo tisti indeks  $n$ , pri katerem se v  $g[n]$  začne  $m$ -ta pojavitev pojava, ki jo želimo analizirati (pri signalih EKG je to lahko segment ST  $m$ -tega srčnega utripa v vhodnem signalu). Imamo tudi poznano (lahko tudi empirično določeno) preslikavo  $\zeta : \mathbb{R} \rightarrow \mathbb{Z}$ . Ta nam vsak  $r_m$  znotraj definicijskega območja preslikave  $\zeta$  preslika v časovno dolžino preiskovanega pojava  $\zeta(r_m)$ , izraženo v številu časovnih vzorcev, s kakršno pričakujemo, da v izvoru signala  $g[n]$  nastopa preiskovani pojav pri vrednosti parametra  $r_m$ . Vektorje vzorcev  $\mathbf{x}_m$  lahko

potem zajemamo iz vhodnega signala  $g[n]$  prilagodljivo glede na parameter  $r_m$  tako, da po definiciji  $\zeta$  v vektorjih  $\mathbf{x}_m$  vselej natančno in v celoti zajamemo analizirani pojav, ne glede na njegovo spreminjajočo se dolžino:

$$\mathbf{x}_m = g[s_m + k] ; \quad k = 0, 1, 2, \dots, \zeta(r_m) - 1 . \quad (3.21)$$

Dolžina naključnega vektorja  $\mathbf{x}_m$  tako ni več enotna, temveč se dinamično prilagaja parametru  $r_m$  in je enaka  $\zeta(r_m)$  časovnih vzorcev.

Naj bo  $LRp(\mathbf{x}_m)$  vektorska funkcija, ki nam poljubni vhodni vzorčni vektor  $\mathbf{x}_m$  poljubne dolžine v skladu z  $\zeta(r_m)$  prevzorči v ekvivalenten vektor primerno izbrane enotne dolžine  $M$  časovnih vzorcev. (Kakšna je primerna izbira enotne dolžine  $M$  bolj podrobno obravnavamo v nadaljevanju.) Potem lahko transformacijo na osnovi ortogonalne matrike  $\Phi$  enotne dimenzije  $M$  iz enačb (3.3), (3.4), (3.12) izračunamo tudi za vhodne vektorje  $\mathbf{x}_m$ , katerih dolžina se razlikuje od dimenzije  $M$  matrike  $\Phi$ , če enačbo ortogonalne transformacije dopolnimo kot

$$\mathbf{y}_m = \Phi^\top LRp(\mathbf{x}_m) . \quad (3.22)$$

Funkcijo  $LRp$  smo implementirali z algoritmom 3.1, ki dinamično prilagaja dolžino vhodnih vektorjev vzorcev (segmenti ST) glede na višino trenutne srčne frekvence po razviti metodi (tabela 3.3, slika 3.2), ki je podrobno opisana v naslednjem poglavju (poglavje 3.5). Temelji na formuli 3.32, ki smo jo na osnovi Bazettove formule (formula 3.25) izpeljali za določitev dolžine segmenta ST in na ekspertno določenih podatkih o položaju dinamične točke merjenja nivoja segmenta ST v odvisnosti od nekaterih izbranih vrednosti srčne frekvence. Segment ST je vsebovan v intervalu QT, oziroma je njegov podinterval. Dinamično točko merjenja nivoja segmenta ST v odvisnosti od nekaterih izbranih vrednosti srčne frekvence pa so postavili eksperti kardiologi med razvojem podatkovne baze LTST DB. Algoritem 3.1 kot vhod sprejme vhodni vektor dolžine  $dimIn$  časovnih vzorcev, zapisan v polju  $\mathbf{vIn}$ , in ga z linearno interpolacijo prevzorči v vektor dolžine  $dimOut$ , ki se pridobi po razviti metodi za določanje dolžine segmenta ST glede na srčno frekvenco pri obdelovanem vzorčnem vektorju in ga zapiše v izhodno polje  $\mathbf{vOut}$ . Algoritem vrednost prve in zadnje komponente vhodnega vektorja ohrani v izhodnem vektorju, vmesne komponente izhodnega vektorja pa na osnovi linearne interpolacije vrednosti komponent vhodnega vektorja izračuna v časovno ekvidistančnih točkah.

```

1  bool IRp(float* vIn, float* vOut, int dimIn, int dimOut)
2
3  /* Take an input vector of dimension dimIn from the array vIn,
4   * resample it by linear interpolation to dimension of dimOut and
5   * return it as the vOut array. Note, the algorithm preserves the
6   * first and the last vector components unchanged and interpolates
7   * the values in between. */
8  {
9      if (dimIn < 2 || dimOut < 2) return false;
10
11     float inc = (dimIn - 1) / (dimOut - 1);
12
13     for (int i = 0; i < dimOut; i++)
14     {
15         vOut[i] = vIn[floor(i*inc)]
16                 + ( (i*inc) - floor(i*inc) )
17                   * ( vIn[floor(i*inc)+1] - vIn[floor(i*inc)] );
18     }
19     return true;
20 }
21

```

### Algoritem 3.1

Algoritem (C++) za prevzorčenje z linearno interpolacijo IRp(). Za vhod sprejme vektor **vIn** poljubne dolžine *dimIn* časovnih vzorcev in ga pretvori v izhodni vektor **vOut** želene dolžine *dimOut* časovnih vzorcev.

Primerno enotno dolžino vzorčnih vektorjev  $M$  lahko izberemo z upoštevanjem enakih meril, na osnovi katerih smo pred tem izbrali frekvenco, s katero vzorčimo vhodni signal. V skladu z Nyquistovim vzorčevalnim teoremom [60] želimo zajeti najvišje frekvenčne komponente, pri katerih ocenjujemo, da še nastopajo za preučevanje pomembni procesi. Če je bila frekvenca vzorčenja izbrana tako, da zajema vse pomembne (morfološke) značilnosti tudi pri najkrajših pričakovanih pojavitvah preučevanega pojava, lahko skladno s tem tudi za enotno dimenzijo transformacije vzamemo najmanjšo pričakovano dolžino prilagodljivega vektorja vhodnega časovnega vzorca. V praksi je frekvenca vzorčenja lahko izbrana tudi tako, da popolno zajame le večino vzorcev, ne pa vseh – tudi najkrajših. V takem primeru bo za enotno dolžino primerneje izbrati vrednost bližje srednji vrednosti pričakovanih dolžin vektorjev vhodnih vzorcev. Če nismo omejeni s strojnimi viri, je sicer zanesljivejša izbira največja pričakovana dolžina vektorjev vhodnih vzorcev. Tipična dolžina segmenta ST znaša 120 ms [7], kar pri frekvenci vzorčenja 250 Hz v podatkovni bazi LTST DB [10] pomeni 30 časovnih vzorcev. Do-

sedanja literatura (poglavje 2.4) za dolžino vzorčnih vektorjev za transformacijo KLT (s konstantno dolžino) pri polovični frekvenci vzorčenja uporablja 16 časovnih vzorcev. Tako smo za enotno dolžino vzorčnih vektorjev segmenta ST ob polni frekvenci vzorčenja 250 Hz pri vhodnih signalih iz podatkovne baze LTST DB izbrali  $M = 32$ .

### 3.4.1 Ocena časovne zahtevnosti implementacije

Proces dinamičnega prilagajanja vhodnega vzorčnega vektorja spreminjajoči se srčni frekvenci zaporedno izračunava posamične komponente enotni dimenziji  $M = 32$  vzorcev prilagojenega vektorja glede na izmerjeno srčno frekvenco. Srčno frekvenco izmerimo na osnovi števila časovnih vzorcev med stabilno referenčno točko F trenutnega in naslednjega srčnega utripa (poglavje 6.2). Ker je srčna frekvenca fiziološko omejena na okvirno trikratnik normalne srčne frekvence v mirovanju, privzamemo, da proces določanja pozicije točke F in trenutne višine srčne frekvence ne preseže časa, ki ga ocenimo s konstanto  $T_h$ . Vhodni signal je v naši implementaciji prednaložen v spominu z naključnim dostopom kot statično podatkovno polje. Dostopi do posamičnih časovnih vzorcev se zato izvršijo v konstantnem času. Vhodni vektor vzorcev segmenta ST implementiramo kot dvojico podatkov – indeks  $s$  polja z vhodnim signalom  $g[\ ]$  in podatek o dolžini trenutnega segmenta ST v obliki števila časovnih vzorcev. Indeks  $s$  označuje začetek segmenta ST. Določen je kot konstantno število časovnih vzorcev za stabilno točko F trenutnega srčnega utripa. Razvito funkcijo za določanje dolžine segmenta ST glede na srčno frekvenco za učinkovito delovanje pripravimo v predračunani tabelirani obliki in jo implementiramo s statičnim podatkovnim poljem. Čas dostopa do ustreznega podatka o dolžini segmenta ST pri izmerjeni srčni frekvenci tako ocenimo s konstanto  $T_{ST}$ . Vse vektorje vzorcev v nadaljnjih procesih prav tako implementiramo kot statična podatkovna polja vnaprej določene največje dolžine. Prilagojeni vektor konstantne dolžine nato pridobimo s postopkom (algoritem 3.1), ki za vsako komponento prilagojenega vektorja izračuna vrednost na osnovi linearizacije dveh na časovni osi sosednjih komponent vhodnega vektorja. Komponente vhodnega vektorja  $g[s + k]$  zajemamo iz vhodnega signala glede na trenutno srčno frekvenco. Ta postopek tako sestavlja še  $M$ -kratna iteracija dveh dostopov do podatkov vhodnega signala, katerih čas izvajanja ocenimo s konstanto  $T_g$ , in zapisa podatka v prilagojeni vektor, katerega čas izvajanja ocenimo s konstanto  $T_v$ , in nabora aritmetičnih operacij, katerih čas izvajanja ocenimo s konstanto  $T_a$ . Potem lahko ocenimo časovno zahtevnost procesa dinamičnega prilagajanja vhodnega vzorčnega vektorja spreminjajoči se

srčni frekvenci kot

$$T_{\text{IRP}} = T_{\text{h}} + T_{\text{ST}} + M \cdot (2T_{\text{g}} + T_{\text{v}} + T_{\text{a}}) , \quad T_{\text{IRP}} = O(M) , \quad (3.23)$$

kjer  $O(\cdot)$  pomeni asimptotično časovno zahtevnost.

Proces samega izračuna koeficientov ortogonalne transformacije, v skladu s formulo (3.22), pridobi glede na trenutno srčno frekvenco prilagojen vektor vzorcev, nato pa izvede skalarni produkt prilagojenega vektorja dolžine  $M$  časovnih vzorcev z največ  $M$  baznimi vektorji, prav tako dolžine  $M$ . Vektor vzorcev, matriko ortogonalne transformacije z baznimi vektorji in vektor koeficientov lahko implementiramo v obliki statičnih polj v spominu z naključnim dostopom. Dostopi do posamičnih vektorskih komponent se tako izvedejo v konstantnem času. Časovno zahtevnost izračuna koeficientov ortogonalne transformacije ocenimo kot

$$T_{\text{C}} = T_{\text{IRP}} + M \cdot (T_{\text{aC}} + M \cdot T_{\text{bC}}) , \quad T_{\text{C}} = O(M^2), \quad (3.24)$$

kjer sta  $T_{\text{aC}}$  in  $T_{\text{bC}}$  oceni konstantnih časov izvajanja pripadajočih aritmetičnih operacij ter branj in zapisovanj podatkov v statičnih podatkovnih poljih,  $O(\cdot)$  pa pomeni asimptotično časovno zahtevnost.

### 3.5 Ocenjevanje dolžine segmenta ST na osnovi srčne frekvence

Dolžina segmenta ST je izrazito odvisna od srčne frekvence, vendar pa preslikava med tema parametroma ni trivialno linearna. A ker algoritmi za izločanje morfoloških značilnik v dosednji praksi niso bili prilagodljivi glede na spreminjajočo se srčno frekvenco in posledično spreminjajočo se dolžino segmenta ST, prav tako ni bilo potreb po metodah za določitev dolžine segmenta ST na osnovi srčne frekvence. Zato so viri na tem področju omejeni.

Za osnovo konstrukcije iskane preslikave med srčno frekvenco in dolžino segmenta ST smo se odločili uporabiti uveljavljeno Bazettovo formulo [8], ki določa glede na srčno frekvenco korigirano dolžino intervala QT (intervala med začetkom vala Q in koncem vala T v elektrokardiogramu, slika 2.1, [9]). Slednjo označimo kot  $QT_{\text{C}}$ . (Pojem korigirane dolžine razlagamo v nadaljevanju.) Segment ST je namreč vsebovan v intervalu QT in v slednjem predstavlja sredinski segment ter obsega okvirno tretjino razpona intervala QT na časovni osi. Zato predpostavimo, da je časovna dolžina segmenta ST premo sorazmerna z dolžino intervala QT na časovni osi. Predpostavko



smo eksperimentalno potrdili, kot je razvidno tudi s slik 7.1-7.6.

Bazettova formula tako izraža

$$QT_C = \frac{QT}{\sqrt{RR}}, \quad (3.25)$$

kjer  $QT$  pomeni izmerjeno dolžino intervala  $QT$ , izraženo v sekundah,  $RR$  pa pomeni razdaljo med valom  $R$  analiziranega srčnega utripa in valom  $R$  srčnega utripa, ki mu sledi, izraženo v sekundah. Vrednost  $RR$  je obratno sorazmerna s srčno frekvenco in jo lahko izrazimo kot

$$RR = \frac{60}{h}, \quad (3.26)$$

kjer  $h$  pomeni srčno frekvenco, izraženo kot število srčnih utripov na minuto [utr/min], izmerjeno ob analiziranem srčnem utripu. Bazettovo formulo tako lahko izrazimo tudi s srčno frekvenco:


$$QT_C = QT \sqrt{\frac{h}{60}}. \quad (3.27)$$

Bazettova formula je bila razvita za diagnostiko posebnega patološkega stanja sindroma dolge dobe  $QT$  [9]. Diagnostični kriterij za slednjega je namreč postavljen kot standardni diagnostični prag  $QT_D = 440$  ms pri povprečni srčni frekvenci v mirovanju  $h_M$  ( $h_M = 60$  utripov v minuti). Toda srčna frekvenca v klinični praksi pogosto znatno odstopa od  $h_M$ . To povzroči spremembo v dolžini intervala  $QT$ , ki pa ni patološka, temveč je zgolj posledica širitve oziroma ožanja srčnega utripa vzdolž časovne osi EKG zaradi spremembe srčne frekvence. Meritve dolžine intervala  $QT$  pri spremenjeni srčni frekvenci tako ni možno več primerjati s standardnim diagnostičnim pragom  $QT_D$ , da bi ugotovili, ali je interval  $QT$  podaljšan zaradi patološkega stanja.

Bazettova formula je empirično postavljen (približen [9]) matematični model, ki se v klinični praksi uporablja za korekcijo izmerjene dolžine intervala  $QT$  glede na srčno frekvenco, kadar slednja odstopa od standardne srčne frekvence  $h_M$ . Za meritev dolžine intervala  $QT$ , izmerjeno ob poljubni srčni frekvenci, nam Bazettova formula oceni, kakšna bi bila dolžina analiziranega intervala  $QT$ , če bi bila srčna frekvenca pri tem srčnem utripu  $h_M$  (slika 3.1). Tako lahko meritev kljub nestandardni srčni frekvenci uporabimo za diagnostiko sindroma dolge dobe  $QT$ .

Slika 3.1

Ilustracija treh primerov srčnih utripov pri različnih srčnih frekvencah: modro je označen utrip pri najmanjši pričakovani srčni frekvenci  $h = 40$  utr/min, črno je označen srčni utrip pri srčni frekvenci  $h = 112$  utr/min in rdeče srčni utrip pri največji pričakovani srčni frekvenci  $h = 180$  utr/min. Razpona, označena v vrhnjem delu slike, prikazujeta interval QT, izmerjen pri srčnem utripu s srčno frekvenco  $h=40$  utr/min in njegovo korigirano dolžino  $QT_C$  po Bazettovi formuli. Označi  $ST_D$  prikazujeta položaj točke merjenja v pozicijah  $J + 60$  ms, kjer je konec segmenta ST pri  $J + 90$  ms in  $J + 80$  ms, kjer je konec segmenta ST pri  $J + 120$  ms, kot določeno po formuli (3.32). Spodaj so prikazane po funkciji v tabeli 3.3 določene dolžine segmenta ST treh prikazanih srčnih utripov glede na njihove srčne frekvence.



Z upoštevanjem predpostavke, da dolžina segmenta ST premo sorazmerno sledi dolžini intervala QT,

$$QT = K \cdot ST, \quad (3.28)$$

$$QT_C = K \cdot ST_C, \quad (3.29)$$

pa lahko na osnovi Bazettove formule (3.27) ter relacij (3.28) in (3.29) zapišemo formulo tudi za segment ST,

$$K \cdot ST_C = K \cdot ST \sqrt{\frac{h}{60}}. \quad (3.30)$$

Ta nam dolžino segmenta ST pri povprečni srčni frekvenci v mirovanju  $ST_C$  poveže

z dolžino segmenta ST pri izmerjeni srčni frekvenci  $h$ , ki jo označimo kot  $ST$ . Za svoje namene želimo izračunati dolžino  $ST$ , izmerjeno pri poljubni srčni frekvenci  $h$ , na osnovi, za zdaj predpostavimo, da znane dolžine segmenta ST ob povprečni srčni frekvenci v mirovanju (brez patoloških sprememb)  $ST_C$ . Zato izrazimo količino  $ST$  in poenostavimo (eliminiramo  $K$ ):

$$ST = ST_C \sqrt{\frac{60}{h}}. \quad (3.31)$$

Podatek o dolžini segmenta ST pri povprečni srčni frekvenci v mirovanju  $ST_C$  kot parameter formule (3.31), pridobimo iz pravil za določitev položaja točke merjenja nivoja segmenta ST, ki so jih definirali eksperti kardiologi pri razvoju podatkovne baze LTST DB [10]. Točka merjenja nivoja segmenta ST je bila za interval srčnih frekvenc  $h < 100$  postavljena 80 ms za kolenom J, kar predstavlja  $\frac{2}{3}$  standardne (statične) dolžine segmenta ST (slika 2.1). Na osnovi tega razmerja lahko iz podatka o ekspertno definiranim položaju točke merjenja nivoja segmenta ST (izraženega kot razdalje od začetka segmenta ST, tj. od kolena J)  $q$ , pri določeni srčni frekvenci  $h$ , definiramo dolžino segmenta ST kot

$$ST_D = \frac{3}{2}q. \quad (3.32)$$

Vendar slednja pravila iz LTST DB za položaj točke merjenja nivoja ST, prav tako pa tudi sorodna pravila, ki so uporabljana v redni klinični praksi, niso določena natanko za povprečno srčno frekvenco v mirovanju, kot pričakuje Bazettova formula in posledično formula (3.31), temveč so pravila v redni klinični praksi postavljena za dva intervala vrednosti srčne frekvence (tabela 3.1) [61]. Podobno so v intervalih postavljeni tudi podatki za položaj točke merjenja nivoja segmenta ST v podatkovni bazi LTST DB, le še nekoliko podrobneje (tabela 3.2) [10].

Zato za izračun dolžine segmenta ST pri povprečni srčni frekvenci v mirovanju  $ST_C$  na osnovi podane dolžine  $ST = ST_D$  in pripadajoče srčne frekvence  $h = h_D$  uporabimo formulo (3.30). Tako pridobljeni podatek  $ST_C$  nato uporabimo kot parameter v (3.31). To lahko izvedemo tudi v enem koraku, če v formuli (3.30) postavimo  $ST = ST_D$  in  $h = h_D$  in jo z izraženim  $ST_C$  vstavimo v formulo (3.31):

$$ST = ST_D \sqrt{\frac{h_D}{h}}, \quad (3.33)$$

Tabela 3.1

Tradicionalna položaja za ocenjevanje nivoja segmenta ST glede na srčno frekvenco, kot ju definira ustaljena kardiološka praksa za namene diagnostike ishemije [61].  $h$  (prvi stolpec) pomeni srčno frekvenco,  $q$  (drugi stolpec) pa ekspertno določen položaj ocenjevanja nivoja segmenta ST glede na začetek le-tega (tj. koleno J) pri srčni frekvenci  $h$ . Podatek  $ST_D$  (tretji stolpec) je po formuli (3.32) iz  $q$  dobljena dolžina segmenta ST.

$h$ [utr/min]	$J+q$ [ms]	$ST_D$ [ms]
$h \leq 120$	$J+80$	120
$h > 120$	$J+60$	90

Tabela 3.2

Pravila za določitev položaja točke merjenja nivoja segmenta ST ob različnih intervalih srčne frekvence, kot so jih definirali eksperti kardiologi pri razvoju podatkovne baze LTST DB [10].  $h$  (prvi stolpec) pomeni srčno frekvenco,  $q$  (drugi stolpec) pa ekspertno določen položaj točke merjenja glede na začetek segmenta ST (tj. koleno J) pri srčni frekvenci  $h$ . Podatek  $ST_D$  (tretji stolpec) je po formuli (3.32) iz  $q$  dobljena dolžina segmenta ST.

$h$ [utr/min]	$J+q$ [ms]	$ST_D$ [ms]
$h < 100$	$J+80$	120
$100 \leq h < 110$	$J+72$	108
$110 \leq h < 120$	$J+64$	96
$h \geq 120$	$J+60$	90

kjer  $ST_D$  predstavlja dolžino segmenta ST, pridobljeno iz ekspertno definiranih podatkov pri postavljeni srčni frekvenci  $h_D$ ,  $ST$  pa je iskana dolžina segmenta ST pri poljubni frekvenci  $h$ .

Če v formulo (3.33) vstavimo formulo (3.32) dobimo povezavo med ekspertno določenim položajem  $q$  točke merjenja nivoja segmenta ST pri srčni frekvenci  $h_D$  (podatki v tabeli 3.2) in dolžino segmenta ST pri poljubni srčni frekvenci  $h$ :

$$ST = \frac{3}{2}q\sqrt{\frac{h_D}{h}}. \quad (3.34)$$

Pri konstrukciji končne različice funkcije, ki nam povezuje srčno frekvenco in dolžino segmenta ST, smo se poleg matematičnega modela (3.33, 3.34), ki smo ga izpeljali na osnovi Bazettove formule, odločili upoštevati tudi podatke za položaj točke merjenja nivoja segmenta ST, ki so jih za nekatere intervale srčne frekvence definirali eksperti kardiologi ob razvoju podatkovne baze LTST DB (tabela 3.2). Na osnovi teh podatkov lahko po formuli (3.32) določimo dolžino segmenta ST. Oba navedena vira smo

združili tako, da


1. na območju srčne frekvence med 100 in 120 utripi v minuti, kjer so ekspertni podatki natančno postavljeni, upoštevamo te (tj. podatke v stolpcu  $ST_D$  tabele 3.2). Z linearno interpolacijo določimo vse točke preslikave na tem območju srčne frekvence.
2. Nato parametere  $q$  in  $h_D$  v formuli (3.34) določimo na osnovi ekspertno določenih podatkov za položaj točke merjenja nivoja segmenta ST iz tabele 3.2 pri srčni frekvenci  $h_D = 120$  utripov v minuti, kjer znaša  $q = 60$  ms (pripadajoča dolžina segmenta ST pa je  $ST_D = ST_{120} = 90$  ms). Sedaj lahko po (3.34) izračunamo s srčno frekvenco korigirano dolžino segmenta ST pri največji pričakovani srčni frekvenci  $h = 180$  utripov v minuti. Dobimo (zaradi največje srčne frekvence) najkrajšo korigirano dolžino segmenta ST, ki znaša  $ST_{180} = 73.48$  ms. Ker bodo naši algoritmi v nadaljevanju delovali v diskretnem prostoru na osnovi frekvence vzorčenja 250 Hz, dobljeno vrednost pretvorimo v enote časovnih vzorcev in celoštevilsko zaokrožimo. Tako dobimo  $ST_{180} = 18$  časovnih vzorcev (tj. pri vzorčenju s frekvenco 250 Hz so časovni vzorci zajeti vsakihi  $t_0 = 4$  ms). Točke med  $ST_{120}$  in  $ST_{180}$  določimo z linearno interpolacijo.
3. Po isti metodi (formula (3.34),  $h_D = 120$ ,  $q = 60$ ) nato izračunamo tudi dolžino segmenta ST pri najmanjši pričakovani srčni frekvenci 40 utripov v minuti  $ST_{40}$ . Izračunana najdaljša korigirana dolžina segmenta ST tako znaša  $ST_{40} = 155.90$  ms oziroma v enotah časovnih vzorcev  $ST_{40} = 39$  časovnih vzorcev. Točke med  $ST_{100}$  in  $ST_{40}$  prav tako določimo z linearno interpolacijo.

S tako pridobljenimi podatki v enotah časovnih vzorcev osnujemo tabelarično intervalno definirano funkcijo dolžine segmenta ST v odvisnosti od srčne frekvence, ki je podana v tabeli 3.3. Na sliki 3.2 je razvita tabelirana funkcija izrisana (rdeča črta – "predlagano"). Točki, v katerih smo potek razvite funkcije uskladili s podatki, ki so v uporabi v diagnostiki in v podatkovni bazi LTST DB (tabela 3.2), sta na sliki označeni

Tabela 3.3

Tabelarično intervalno definirana funkcija dolžine segmenta ST v odvisnosti od srčne frekvence  $h$  (prvi stolpec), v enotah časovnih vzorcev ( $ST$  [časovni vzorci], drugi stolpec) ter na osnovi slednje celoštevilsko zaokrožene vrednosti preračunana dolžina segmenta ST v milisekundah ( $ST$  [ms],  $ST$  [ms] =  $ST$  [časovni vzorci] · (1000 ms/s) / (250 /s), tretji stolpec).

$h$ [utr/min]	$ST$ [časovni vzorci]	$ST$ [ms]
$h < 40$	39	156
$h \geq 40$	39	156
$h \geq 44$	38	152
$h \geq 48$	38	152
$h \geq 52$	37	148
$h \geq 56$	36	144
$h \geq 60$	36	144
$h \geq 64$	35	140
$h \geq 68$	34	136
$h \geq 72$	33	132
$h \geq 76$	33	132
$h \geq 80$	32	128
$h \geq 84$	31	124
$h \geq 88$	31	124
$h \geq 92$	30	120
$h \geq 96$	29	116
$h \geq 100$	28	112
$h \geq 104$	27	108
$h \geq 108$	26	104
$h \geq 112$	25	100
$h \geq 116$	24	96
$h \geq 120$	23	92
$h \geq 124$	22	88
$h \geq 128$	22	88
$h \geq 132$	22	88
$h \geq 136$	21	84
$h \geq 140$	21	84
$h \geq 144$	21	84
$h \geq 148$	20	80
$h \geq 152$	20	80
$h \geq 156$	20	80
$h \geq 160$	20	80
$h \geq 164$	19	76
$h \geq 168$	19	76
$h \geq 172$	19	76
$h \geq 176$	18	72
$h \geq 180$	18	72



Slika 3.2


Prikaz razvite funkcije dolžine segmenta ST (rdeča črta – "predlagano") [ms] v odvisnosti od srčne frekvence  $h$  [utr/min] po podatkih v tabeli 3.3. Za primerjavo je črtkano temno modro ("fiksno") prikazana fiksna dolžina segmenta ST, ki znaša  $ST = 120$  ms, kot so jo uporabljali predhodni algoritmi brez prilagajanja srčni frekvenci. Z vijolično črto ("Bazett") je prikazan graf funkcije na podlagi Bazettove formule (3.33) [ms] v odvisnosti od srčne frekvence  $h$ . Črtkano svetlo modro ("LTST DB") je prikazana dolžina segmenta ST skladno s pravili za določitev položaja točke merjenja nivoja segmenta ST v podatkovni bazi LTST DB [ms] v odvisnosti od srčne frekvence  $h$  po podatkih v tabeli 3.2. Z zeleno črto ("diagnostično") je prikazana dolžina segmenta ST skladno s pravili za določitev položaja ocenjevanja nivoja segmenta ST za diagnostiko ishemije v redni kardiološki praksi [ms] v odvisnosti od srčne frekvence  $h$  po podatkih v tabeli 3.1. Potemnjeno sta označeni točki, v katerih smo potek predlagane razvite funkcije uskladili s predhodnimi diagnostičnimi pravili.

potemnjeno. Na sliki je za primerjavo črtkano temno modro ("fiksno") prikazana tudi fiksna dolžina segmenta ST, ki znaša  $ST = 120$  ms, kot so jo uporabljali predhodni algoritmi brez prilagajanja srčni frekvenci. Z vijolično črto ("Bazett") je na sliki prikazana osnova na podlagi Bazettove formule (3.33). Črtkano svetlo modro ("LTST DB") je prikazana tudi dolžina segmenta ST skladno s pravili za določitev položaja točke merjenja nivoja segmenta ST v podatkovni bazi LTST DB (po podatkih v tabeli 3.2). Z zeleno črto ("diagnostično") pa je prikazana dolžina segmenta ST skladno s pravili za določitev položaja ocenjevanja nivoja segmenta ST za diagnostiko ishemije v redni kardiološki praksi [ms] v odvisnosti od srčne frekvence  $h$  po podatkih v tabeli 3.1.

Natančnost skonstruirane funkcije, ki nam povezuje srčno frekvenco in dolžino segmenta ST, smo potrdili eksperimentalno, kot prikazuje primer srčnega utripa na sliki

### Slika 3.3

Primer EKG srčnega utripa s srčno frekvenco 60 utripov v minuti iz drugega odvoda posnetka sz00111 podatkovne baze LTST DB ob času 10:30:02. Po razviti funkciji (tabela 3.3) ocenjena dolžina segmenta ST (140 ms pri srčni frekvenci 60 utripov v minuti) je prikazana nad območjem segmenta ST v elektrokardiogramu srčnega utripa na sliki (potemnjeni interval).



3.3. V poglavju 7.1, kjer podrobno evaluiramo učinkovitost razvite funkcije, si na realnih podatkih potrdimo, da ta dobro sledi spremenljivi dolžini segmenta ST tako pri visokih, srednjih kot nizkih srčnih frekvencah.



*Prilagodljiva transformacija  
Karhunena in Loèva*

Diskretna ortogonalna transformacija Karhunen in Loève (KLT) temelji na medsebojno ortogonalnih lastnih vektorjih, urejenih v padajočem vrstnem redu pripadajočih lastnih vrednosti kovariančne matrike, zgrajene na osnovi učne množice vhodnih vzorčnih vektorjev. KLT je optimalna v smislu, da lahko vhodni vektor, če ga sestavljajo morfološke komponente, prisotne v učni množici, aproksimira s pričakovano minimalno srednjo kvadratno napako ob poljubno znižani dimenziji transformiranega prostora v primerjavi z drugimi ortogonalnimi transformacijami pri enaki dimenziji [3]. Hkrati je takšna konstrukcija optimalne zmanjšane baze tudi računsko učinkovita. Transformacija KLT je tako učinkovito orodje za izločanje značilnih morfoloških lastnosti, denimo fizioloških signalov in parametričen opis njihovih oblik, kjer nam vnaprej niso znane porazdelitve verjetnosti vektorjev vhodnih vzorcev. S transformacijo KLT lahko neperiodičen stohastičen proces preslikamo v prostor nekoreliranih ortonormalnih baznih funkcij, brez potrebe po podrobnem vnaprejšnjem poznavanju verjetnostne strukture problemskega prostora. Posebna lastnost transformacije KLT je tako možnost preslikave vektorjev vzorcev preučevanih signalov v prostor, ki je optimalno prilagojen preučevanim razredom vhodnih signalov. Bazo transformacije sestavljajo lastni vektorji kovariančne matrike, urejeni po pričakovani moči prispevkov posamičnih komponent transformiranega prostora v izvornih signalih učne množice, ki predstavljajo lastne vrednosti, ki pripadajo posamičnim lastnim vektorjem.

Opisana optimalnost transformacije drži za razrede vhodnih vzorcev, ki so dobro zastopani v učni množici. Pri signalih EKG so to čisti srčni utripi brez motenj, katerih morfolologija ustreza pomembnim in pogosto nastopajočim oblikam, medtem ko je aproksimacija vzorcev, ki odstopajo in v učni množici niso dobro zastopani, kot denimo različne motnje, pričakovano neučinkovita. Ta lastnost transformacije KLT je pričakovana in izhaja iz njene definicije ter je prav tako želena in jo lahko tudi izkoristimo v algoritmih za izločanje motenj [16, 17].

#### 4.1 *Ortogonalna transformacija KLT*

V nadaljevanju povzemamo osnove transformacije Karhunen in Loève, ki jo v našem delu uporabljamo kot orodje. Podrobnejša teorija in ozadja so na voljo v literaturi [3, 7, 62–64]. Transformacijo bomo definirali nad razredom naključnih vektorjev  $\{\mathbf{x}\}$  dolžine  $M$  časovnih vzorcev v  $P$ -dimenzionalnem evklidskem prostoru ( $M < P$ ). Želimo skonstruirati učinkovito bazo za aproksimacijo vektorjev  $\{\mathbf{x}\}$  z vidika minimalne pričakovane kvadratne napake pri optimalno zmanjšani dimenziji transformiranega

prostora. Naj vsak poljubni vektor  $\mathbf{x} = (x_1, x_2, x_3, \dots, x_M)^\top$ , ki predstavlja vzorec nekega pojava v nekem signalu, ki smo ga vzorčili v  $M$  točkah njegovega časovnega poteka (poteke segmenta ST v elektrokardiogramu), pripada enemu izmed  $L$  možnih razredov  $\{\omega_i, i = 1, 2, 3, \dots, L\}$ , za katerega apriorna verjetnost njegovega nastopa znaša  $p(\omega_i)$ . Vsak razred vzorcev centraliziramo tako, da odštejemo povprečje  $\mu_i$  vektorjev  $\mathbf{x}_i$ :

$$\mathbf{z}_i = \mathbf{x}_i - \mu_i. \quad (4.1)$$

Centralizirani naključni vzorčni vektor  $\mathbf{z}_i$  lahko izrazimo kot linearno kombinacijo

$$\mathbf{z}_i = \sum_{j=1}^M c_{ij} \Phi_{Kj}, \quad (4.2)$$

kjer so  $\Phi_{Kj}$  medsebojno ortogonalni vektorji, ki zadoščajo relaciji ortogonalnosti

$$\Phi_{Kj} \Phi_{Kk} = \delta_{jk} ; \quad j = 1, 2, \dots, M ; \quad k = 1, 2, \dots, M, \quad (4.3)$$

$\delta_{jk}$  pa predstavlja Kroneckerjevo delta funkcijo (3.7).

Koeficienti  $c_{ij}$  so glede na razrede vzorcev  $\omega_i$  medsebojno nekorelirani in velja

$$\sum_{i=1}^L p(\omega_i) E\{c_{ij} c_{ik}\} = \sigma_j^2 \delta_{jk} ; \quad j = 1, 2, \dots, M ; \quad k = 1, 2, \dots, M, \quad (4.4)$$

kjer so  $\sigma_j$  standardne deviacije koeficientov  $c_{ij}$ .

Vektorji  $\Phi_{Kj}$  iz enačbe (4.2) nam tako predstavljajo bazne vektorje transformacije KLT, ki jih pridobimo kot lastne vektorje kovariančne matrike  $\mathbf{R}$  iz vektorjev  $\mathbf{z}_i$ :

$$\mathbf{R} = \sum_{i=1}^L p(\omega_i) E\{\mathbf{z}_i \mathbf{z}_i^\top\}, \quad (4.5)$$

pri čemer so

$$\lambda_j = \sigma_j^2 \quad (4.6)$$

lastne vrednosti matrike  $\mathbf{R}$ ,  $\sigma_j^2$  pa so standardne deviacije koeficientov. Kovariančna matrika  $\mathbf{R}$  je simetrična, njeni lastni vektorji, ki nam predstavljajo bazo transforma-

cije KLT pa so medsebojno ortogonalni. Lastne vektorje  $\Phi_{Kj}$  in pripadajoče lastne vrednosti  $\lambda_j$  za kovariančno matriko  $\mathbf{R}$  pridobimo z rešitvijo enačbe

$$\mathbf{R} \Phi_{Kj} = \lambda_j \Phi_{Kj} . \quad (4.7)$$

Množico baznih vektorjev ( $\Phi_{K1}, \Phi_{K2}, \Phi_{K3}, \dots, \Phi_{KM}$ ) lahko obravnavamo kot matriko  $\Phi_K$  in formulo (4.2) izrazimo v matrični obliki

$$\mathbf{z}_i = \Phi_K \mathbf{c}_i , \quad (4.8)$$

ki je ekvivalentna formuli (3.3), njen inverz pa nam da formulo za izračun koeficientov transformacije KLT:

$$\mathbf{c}_i = \Phi_K^\top \mathbf{z}_i , \quad (4.9)$$

ki je ekvivalentna formuli (3.12).

Tako dobljene bazne vektorje transformacije KLT  $\Phi_{Kj}$  uredimo po vrstnem redu padajočih lastnih vrednosti  $\lambda_j$ , ki jim pripadajo:

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N \geq \dots \geq \lambda_M , \quad (4.10)$$

kjer  $M$  predstavlja dimenzijo ortogonalne transformacije. Z izborom  $N$  ( $N < M$ ) lahko določimo optimalno zmanjšano dimenzijo transformiranega prostora, saj je transformacija KLT zasnovana tako, da prvih  $N$  vektorskih komponent transformiranega prostora (koeficienti transformacije  $c_{ij}$ ) v takšnem vrstnem redu pomeni največji pričakovani prispevek energije (tj. za vzorce vhodnega signala z lastnostmi, ki so v učni množici dobro zastopani).

Transformacija KLT ima tako naslednje lastnosti z vidikov optimalnosti:

1. Rekonstrukcija vektorja  $\mathbf{z}_i$  z aproksimacijo

$$\hat{\mathbf{z}}_i = \sum_{j=1}^N c_{ij} \Phi_{Kj} , \quad (4.11)$$

kjer  $N < M$ , prinese srednjo kvadratno napako

$$e^2(N) = \sum_{i=1}^L p(\omega_i) E\{|\mathbf{z}_i - \hat{\mathbf{z}}_i|^2\} , \quad (4.12)$$

ki je minimalna za vsak izbrani  $N$  v primerjavi z drugimi ortogonalnimi transformacijami. Takšna transformacija nam zatorej zagotovi minimalno pričakovano srednjo kvadratno napako, če aproksimiramo vhodni vektor s poljubnim številom  $N$  prvih baznih vektorjev v skladu s padajočim vrstnim redom pripadajočih lastnih vrednosti v primerjavi z drugimi ortogonalnimi transformacijami.

2. Definirajmo energijo vektorja  $\mathbf{z}$  kot  $\mathbf{z}\mathbf{z}^\top$ . Potem nam  $\xi_j$ :

$$\xi_j = \frac{\lambda_j}{\sum_{k=1}^M \lambda_k} \quad (4.13)$$

pomeni pričakovani delež energije vektorja  $\mathbf{z}$ , ki pripada bazni funkciji  $\Phi_{K_j}$ . Nadalje lahko preko  $N$  baznih funkcij izračunamo pričakovani delež celotne energije za izbrane bazne funkcije:

$$\xi(N) = \sum_{i=1}^N \xi_j = \sum_{i=1}^N \frac{\lambda_j}{\sum_{k=1}^M \lambda_k} . \quad (4.14)$$

Če za aproksimacijo tako uporabimo prvih  $N$  baznih funkcij, lahko razmerje med srednjo kvadratno napako za izbrani  $N$  in pričakovano energijo vektorja  $\mathbf{z}$ ,

$$\eta(N) = \frac{e^2(N)}{E\{\mathbf{z}^\top \mathbf{z}\}} , \quad (4.15)$$

izračunamo kot

$$\eta(N) = 1 - \sum_{i=1}^N \xi_j . \quad (4.16)$$

3. Prav tako velja, da je za aproksimacijo (4.11) pri vsakem izbranem  $N$  ( $N < M$ )

funkcija entropije

$$H(N) = - \sum_{j=N}^M \lambda_j \log \lambda_j \quad (4.17)$$

minimalna v primerjavi z drugimi ortogonalnimi transformacijami. Vsak naslednji koeficient, ki ga dodamo k aproksimaciji, tako prinaša minimalno spremembo entropije, oziroma je tako pričakovana informacija o transformiranem vhodnem vektorju najmočnejše vsebovana v prvih  $N$  koeficientih v padajočem vrstnem redu pripadajočih lastnih vrednosti za vsak izbrani  $N$ .

Pri tem se je treba zavedati, da slednje govori le o pričakovani srednji kvadratni napaki. Napaka v praksi je lahko večja, še zlasti pri vhodnih vzorcih, ki odstopajo od dobro zastopanih razredov v učni množici, na osnovi katerih je bila grajena kovariančna matrika  $\mathbf{R}$ . Vzorci morajo namreč ustrezati pogoju  $E(\mathbf{z}_i) = 0$ , tj. morajo biti centralizirani s srednjim vektorjem (4.1), ki pa ga pri neznanih vhodnih vzorcih praviloma ne poznamo. Če privzamemo, da imajo vsi razredi vzorcev enak srednji vektor, lahko tega pridobimo iz učne množice. Ta pristop nam sicer ne zagotovi optimalnih rezultatov za vse razrede vhodnih vzorcev, kljub temu pa zajame informacijo o preučevanih razredih [63]. Potem lahko kovariančno matriko 4.5 zapišemo kot

$$\mathbf{R} = E\{(\mathbf{x} - \boldsymbol{\mu}_0)(\mathbf{x} - \boldsymbol{\mu}_0)^\top\} = \sum_{i=1}^L p(\omega_i) E\{(\mathbf{x}_i - \boldsymbol{\mu}_0)(\mathbf{x}_i - \boldsymbol{\mu}_0)^\top\}, \quad (4.18)$$

kjer je  $\boldsymbol{\mu}_0$  srednji vektor

$$\boldsymbol{\mu}_0 = E(\mathbf{x}) ; \quad \forall \mathbf{x} . \quad (4.19)$$

Ob znatni prisotnosti izrazito odstopajočih šumnih vzorcev, ki ne pripadajo nobenemu od preučevanih razredov – ti so v realnih fizioloških signalih, kot je EKG, pogost pojav, lahko pride do prevelike občutljivosti pridobljenih lastnih vektorjev na takšne motnje. V izogib tovrstnim kvarnim vplivom lahko uporabimo metodo približnih jeder (angl. kernel approximation) [65], po kateri odstopajoče šumne vzorce izločimo in vzorce posamičnih razredov nadomestimo z njihovimi povprečji. Tako dobimo ro-

bustno kovariančno matriko

$$\mathbf{R}_{\text{rob}} = E\{(\mathbf{x} - \boldsymbol{\mu}_0)(\mathbf{x} - \boldsymbol{\mu}_0)^\top\} = \sum_{i=1}^L p(\omega_i) E\{(\bar{\mathbf{x}}_i - \boldsymbol{\mu}_0)(\bar{\mathbf{x}}_i - \boldsymbol{\mu}_0)^\top\}, \quad (4.20)$$

kjer je  $\bar{\mathbf{x}}_i$  povprečni vektor  $i$ -tega razreda  $K_i$ ,

$$\bar{\mathbf{x}}_i = E(\mathbf{x}) ; \quad \forall \mathbf{x} : \mathbf{x} \in K_i, \quad (4.21)$$

srednji vektor  $\boldsymbol{\mu}_0$  pa definiramo kot

$$\boldsymbol{\mu}_0 = E(\mathbf{x}) ; \quad \forall \mathbf{x}. \quad (4.22)$$

Lastne vrednosti, ki jih pridobimo iz kovariančne matrike  $\mathbf{R}_{\text{rob}}$ , so funkcija povprečij razredov vhodnih vzorcev. Z enotnim povprečjem razredov ohranimo informacijo o skupnih lastnostih vzorcev, ki pripadajo posamičnim razredom in tako z uporabo metode približnih jeder pridobimo kovariančno matriko in nadalje lastne vektorje kot bazo transformacije KLT na robusten način.

Če transformacijo 4.9 uporabimo na naključnem vhodnem vektorju  $\mathbf{x}$ , dobimo vektor koeficientov transformacije KLT  $\mathbf{y}$ , oziroma vektor značilk:

$$\mathbf{y} = \boldsymbol{\Phi}_K^\top \mathbf{x}, \quad (4.23)$$

lastne vrednosti kovariančne matrike pa predstavljajo pričakovane variance takšnih značilk:

$$\lambda_j = \sigma_j^2 = \sum_{i=1}^L p(\omega_i) E\{(y_{ij} - (v_{ij} + v_{0j}))^2\}, \quad (4.24)$$

kjer  $v_{ij}$  predstavlja transformirano srednjo vrednost značilke  $y_{ij}$  oziroma  $j$ -to komponento transformiranega srednjega vektorja  $\boldsymbol{\mu}_i = E\{(\mathbf{x}_i - \boldsymbol{\mu}_0)\}$  vektorjev  $\mathbf{x}_i$ , ki pripadajo  $i$ -temu razredu relativno glede na srednji vektor  $\boldsymbol{\mu}_0$ ,  $v_{0j}$  pa je  $j$ -ta komponenta transformiranega srednjega vektorja  $\boldsymbol{\mu}_0$  (tj. povprečja celotne množice vzorcev).

Normirana residualna napaka rekonstrukcije

$$\hat{\mathbf{x}}_N = \sum_{j=1}^N c_{ij} \boldsymbol{\Phi}_{Kj}^\top \quad (4.25)$$

primera posamičnega vhodnega vzorca  $\mathbf{x}_i$  naključnega vektorja  $\mathbf{x}$  z  $M$  komponentami aproksimiranega v  $N$  ( $N < M$ ) najpomembnejših dimenzijah transformacije znaša tako

$$r_{\mathbf{x}}(N) = \frac{\|\hat{\mathbf{x}}_N - \mathbf{x}\|}{\|\mathbf{x}\|} = \frac{\sqrt{\frac{1}{M} \sum_{i=1}^M (\hat{\mathbf{x}}_{Ni} - \mathbf{x}_i)^2}}{\sqrt{\frac{1}{M} \sum_{i=1}^M (\mathbf{x}_i)^2}}. \quad (4.26)$$

## 4.2 Mahalanobisova razdalja

Pogosto nas zanima, kako močno se razlikujeta poljubna vektorja morfoloških značilk. V smislu prostorske predstavitve rezultatov transformacije lahko za takšno mero uporabimo Mahalanobisovo razdaljo  $d(\mathbf{y}(j), \mathbf{y}(k))$  med vektorjema koeficientov KLT  $j$ -tega in  $k$ -tega vzorca [7]:

$$d^2(\mathbf{y}(j), \mathbf{y}(k)) = (\mathbf{y}(j) - \mathbf{y}(k))^T \mathbf{C}^{-1} (\mathbf{y}(j) - \mathbf{y}(k)), \quad (4.27)$$

kjer  $\mathbf{C}^{-1}$  predstavlja inverz kovariančne matrike vektorjev koeficientov transformacije KLT učne množice. Matrika  $\mathbf{C}^{-1}$  je diagonalna in simetrična, koeficienti transformacije KLT pa so medsebojno statistično neodvisni. Nediagonalni elementi  $\mathbf{C}^{-1}$  so zato enaki 0. V razdalji  $d$  sta zato vektorja  $\mathbf{y}(j)$  in  $\mathbf{y}(k)$  normalizirana s pripadajočo standardno deviacijo tako, da je njuna standardna deviacija enaka 1 [7].

## 4.3 Gradnja kovariančne matrike z vektorji učnih vzorcev prilagodljive dolžine

Kot smo opisali v poglavju 3.4, pri analizi fizioloških signalov pogosto naletimo na pojav, ki bi ga želeli preučevati s pomočjo ortogonalne transformacije, a se njegovo trajanje med različnimi pojavitvami znatno spreminja. Pogosto na to vplivajo neke merljive zunanje okoliščine oziroma zunanji parametri, ki jih lahko določimo, kot je pri EKG srčna frekvenca. Ker signale vzorčimo z enotno frekvenco vzorčenja, so posledično vektorji vhodnih vzorcev, ki zajemajo pojav našega interesa, različnih dolžin. Če želimo takšen pojav preučevati s transformacijo KLT, na težavo uporabe tako spreminjajočih se vektorjev vzorcev naletimo že pri gradnji kovariančne matrike. Formula (4.20) namreč za vhodne vzorce  $\mathbf{x}$  po definiciji predvideva vhodne vektorje enakih (časovnih) dolžin.



Če imamo ob pojavitvah pojava, ki ga analiziramo, na razpolago dodaten parameter  $r$  (pri signalih EKG srčna frekvenca) in preslikavo  $\zeta(r)$ , ki nam določata časovno trajanje posamičnih pojavitev preiskovanega pojava, lahko vzorce iz vhodnega signala zajemamo s prilagodljivo dolžino vzorčnih vektorjev trajanju posamičnih pojavitev pojava. Potem lahko vektorje vhodnih vzorcev učne množice, ki jih uporabimo za gradnjo kovariančne matrike, z algoritmom 3.1 za prevzorčenje z linearno interpolacijo preslikamo v prostor enotne dolžine, kot je opisano v poglavju 3.4. Predmet naše študije je segment ST elektrokardiograma, pri katerem se njegova časovna dolžina spreminja glede na srčno frekvenco, kot prikazuje slika 3.1. Preslikavo  $\zeta(h)$  med srčno frekvenco  $h$  ( $r = h$ ) in dolžino segmenta ST smo razvili na podlagi matematičnega modela, ki smo ga izpeljali iz Bazettove formule [8] (poglavje 3.4) in podatkov o dolžini segmenta ST v odvisnosti od srčne frekvence, ki jih izpeljemo iz ekspertno določenih podatkov, kot so jih postavili eksperti kardiologi ob razvoju podatkovne baze LTST DB [10] za položaj točke merjenja nivoja segmenta ST (poglavje 3.4). Slednji so bili določeni za intervale najpogostejših srčnih frekvenc  $h < 100$ ,  $100 \leq h < 110$ ,  $110 \leq h < 120$ ,  $h \geq 120$ . V skladu z Bazettovo formulo pridobimo vrednosti dolžine segmenta ST ob skrajnih srčnih frekvencah ( $h \leq 40$  in  $h \geq 180$ ). Na osnovi tako pridobljenih referenčnih točk z linearno interpolacijo generiramo tabelarično preslikavo  $\zeta(h)$  (tabela 3.3, slika 3.2).

Sedaj lahko kovariančno matriko  $\mathbf{R}_{rob}$  gradimo na osnovi vektorjev vhodnih učnih vzorcev, ki jih iz vhodnega učnega signala zajemamo s spremenljivo dolžino tako, da slednjo dinamično prilagajamo natančni časovni dolžini (izraženi v številu časovnih vzorcev pri dani frekvenci vzorčenja) vsake posamične pojavitve preučevanega pojava, ki je zajeta v posamičnem  $\mathbf{x}$ :

$$\mathbf{R}_{rob} = E\{(lRp(\mathbf{x}) - \boldsymbol{\mu}_0)(lRp(\mathbf{x}) - \boldsymbol{\mu}_0)^\top\} = \sum_{i=1}^L p(\omega_i) E\{(\bar{\mathbf{x}}_i - \boldsymbol{\mu}_0)(\bar{\mathbf{x}}_i - \boldsymbol{\mu}_0)^\top\}, \quad (4.28)$$

kjer je  $\bar{\mathbf{x}}_i$  povprečni vektor  $i$ -tega razreda  $K_i$ ,

$$\bar{\mathbf{x}}_i = E(lRp(\mathbf{x})) ; \quad \forall \mathbf{x} : \mathbf{x} \in K_i, \quad (4.29)$$

srednji vektor  $\boldsymbol{\mu}_0$  definiramo kot

$$\boldsymbol{\mu}_0 = E(lRp(\mathbf{x})) ; \quad \forall \mathbf{x}, \quad (4.30)$$

$lRp(\mathbf{x})$  pa je vektorska funkcija, ki nam poljubni vektor vhodnega vzorca  $\mathbf{x}$  poljubne dolžine v skladu z  $\zeta(r)$  prevzorči v ekvivalenten vektor primerno izbrane enotne dolžine  $M$  vzorcev (poglavje 3.4).

Pri gradnji kovariančne matrike z upoštevanjem spreminjajočega se trajanja preučevanega pojava zagotovimo večjo skladnost učnih vzorcev istih razredov, ki se razlikujejo le v trajanju. Zaradi tako zmanjšane variabilnosti vzorcev se pri povprečenju učnih vektorjev znotraj posamičnih razredov ob robustni gradnji kovariančne matrike ohrani več informacije o morfologiji posamičnega razreda. V robustnem procesu izgradnje kovariančne matrike pa so izločeni tudi vplivi morfologij izrazito odstopajočih vzorcev. Od tako ustvarjenih baznih funkcij pričakujemo izrazitejše zajemanje v učni množici najbolj prisotnih morfologij in posledično natančnejše zaznavanje pomembnih morfologij neznanih vhodnih vzorcev z izračunanimi koeficienti transformacije in tako tudi večjo razločljivost med vzorci različnih razredov.

#### 4.4 Izdelava novih baznih funkcij KLT za segment ST

Za izdelavo baznih vektorjev oziroma baznih funkcij KLT za segment ST elektrokardiograma smo uporabili robusten algoritem za gradnjo kovariančne matrike z dinamičnim prilagajanjem dolžine vhodnih vektorjev vzorcev (poglavje 4.3). Nove bazne funkcije so bile pridobljene na osnovi celotne podatkovne baze LTST DB na posamičnih odvodih EKG. Ker želimo zmožnost analize poljubnega odvoda EKG z enotnimi baznimi funkcijami, smo posamične odvode posnetkov LTST DB obravnavali kot ločene enokanalne signale in jih kot takšne uporabili za gradnjo kovariančne matrike. Slednje je upravičeno tudi zato, ker posamični kanali posnetkov podatkovne baze LTST DB, v katerih so zapisani podatki posamičnih odvodov EKG, ne vsebujejo vedno enakega fiziološkega odvoda. Tako smo pridobili 15.661.886 vektorjev časovnih vzorcev segmentov ST iz 7.830.943 čistih srčnih utripov iz celotne podatkovne baze LTST DB.

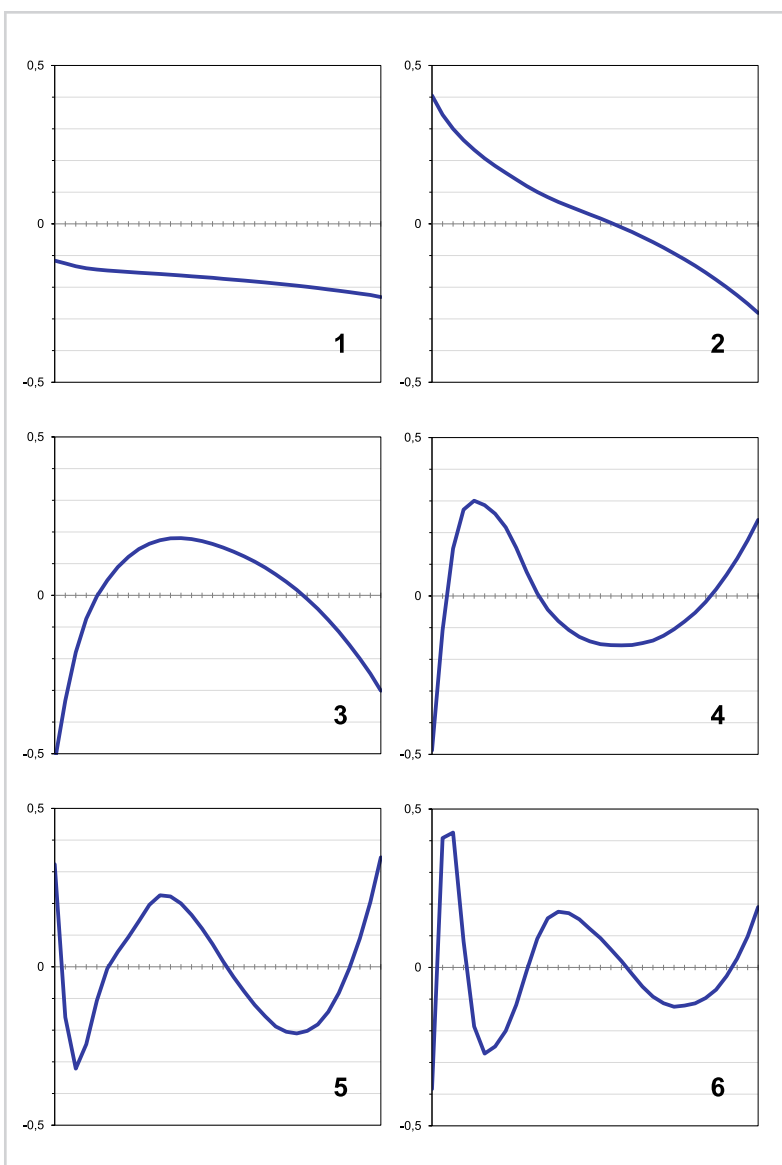
Vhodne vektorje na osnovi tako pripravljene učne množice tvorimo iz segmentov ST iz elektrokardiogramov srčnih utripov. Časovne vzorce segmentov ST iz vhodnega signala EKG zajemamo v vhodne vektorje od točke  $F(i, j) + 40$  ms do točke  $F(i, j) + 40 + ST_{h(i, j)}$  ms, kjer nam  $i$  predstavlja indeks (prvega ali drugega) odvo-

da v posnetku LTST DB,  $j$  predstavlja zaporedni indeks posamičnega srčnega utripa,  $F(i, j)$  pa predstavlja stabilno referenčno točko v vsakem srčnem utripu, kot jih je postavil sistem za odkrivanje motenj srčnega ritma ARISTOTLE v predhodnih fazah predobdelave (poglavje 6.1).  $ST_{h(i,j)}$  predstavlja dolžino segmenta ST, kot je za srčno frekvenco pri posamičnem srčnem utripu  $h(j)$  definirana v tabeli 3.3. Dolžina vhodnih vektorjev časovnih vzorcev se tako za vsak posamični srčni utrip spremeni in je enaka dolžini segmenta ST v enotah časovnih vzorcev iz tabele 3.3 pri srčni frekvenci  $h(j)$  posamičnega vektorja, zajetega iz srčnega utripa  $j$ .

Vhodne vektorje časovnih vzorcev s formulo 4.28 prilagodimo izbrani enotni dolžini, ustrezno enotni dimenziji transformacije,  $M = 32$  časovnih vzorcev. Enotna dolžina je bila izbrana usklajeno z določili tradicionalnih algoritmov, ki so za (neprilagodljivo) jemanje časovnih vzorcev segmenta ST ocenili dolžino le-tega na 128 ms [17]. Upoštevajoč frekvenco vzorčenja, ki so jo v LTST DB določili eksperti kardiologi ob njenem razvoju tako, da ustrezno zajame vse klinično pomembne morfološke značilnosti in znaša 250 Hz, enotna dolžina vhodnih vektorjev znaša  $M = 32$  vzorcev (poglavje 3.4).


Vsak posamični v podatkovni bazi LTST DB ekspertno označen interval odstopanja segmenta ST (posebej intervali prehodnih ishemičnih epizod in posebej intervali prehodnih neishemičnih epizod) in vsak posamični interval med intervali odstopanj v posamičnih odvodih vseh posnetkov podatkovne baze nam predstavlja svoj razred vektorjev časovnih vzorcev segmentov ST s skupno morfologijo. V skladu z metodo približnih jeder (angl. kernel approximation) po formuli (4.28) v algoritmu vsak razred nadomestimo s srednjim vektorjem tega razreda, ki ga centraliziramo tako, da mu odštejemo srednji vektor vseh ustvarjenih razredov. Robustno kovariančno matriko, ki jo pridobimo na takšen način, smo zgradili iz 1642 intervalov prehodnih ishemičnih epizod segmenta ST, 510 intervalov prehodnih neishemičnih epizod segmenta ST in 2298 intervalov med prehodnimi epizodami, pri katerih podatkovna baza LTST DB ne označuje odstopajoče morfologije v segmentu ST.

Sliki 4.1 in 4.2 prikazujeta nove bazne funkcije za transformacijo KLT segmenta ST elektrokardiograma, ki smo jih pridobili po opisanem postopku na osnovi celotne podatkovne baze LTST DB z robustnim prilagodljivim algoritmom za gradnjo kovariančne matrike, ki se dinamično prilagaja zaradi spreminjajoče se srčne frekvence spreminjajoči se dolžini vhodnih vzorcev. V primerjavi s predhodnimi baznimi funkcijami KLT, uporabljenimi v starejših algoritmihi (za izločanje motenj v prostoru transforma-



Slika 4.1

Bazne funkcije KLT 1 do 6 za segment ST elektrokardiograma, pridobljene na celotni podatkovni bazi LTST DB z robustnim srčni frekvenci in skladno s slednjo dolžini vhodnih vzorcev prilagodljivim algoritmom za gradnjo kovariančne matrike.

*Slika 4.2*

Bazne funkcije KLT 7 do 12 za segment ST elektrokardiograma, pridobljene na celotni podatkovni bazi LTST DB z robustnim srčni frekvenci in skladno s slednjo dolžini vhodnih vzorcev prilagodljivim algoritmom za gradnjo kovariančne matrike.

cije KLT, [17], poglavje 6.1), ki so bile pridobljene na manjši podatkovni bazi ESC DB preko dveh odvodov hkrati, so nove bazne funkcije pridobljene na posamičnih odvodih na celotni podatkovni bazi LTST DB, ki je okvirno desetkrat večjega obsega kot ESC DB. Zato zajemajo bistveno širši nabor različnih patoloških in nepatoloških značilnih morfologij in sprememb v morfologiji segmenta ST. Od takšnih baznih funkcij tako lahko pričakujemo boljše reprezentativnost pomembnih morfologij in boljše razločevanje med fiziološkimi pojavi, ki se v teh morfologijah odražajo.

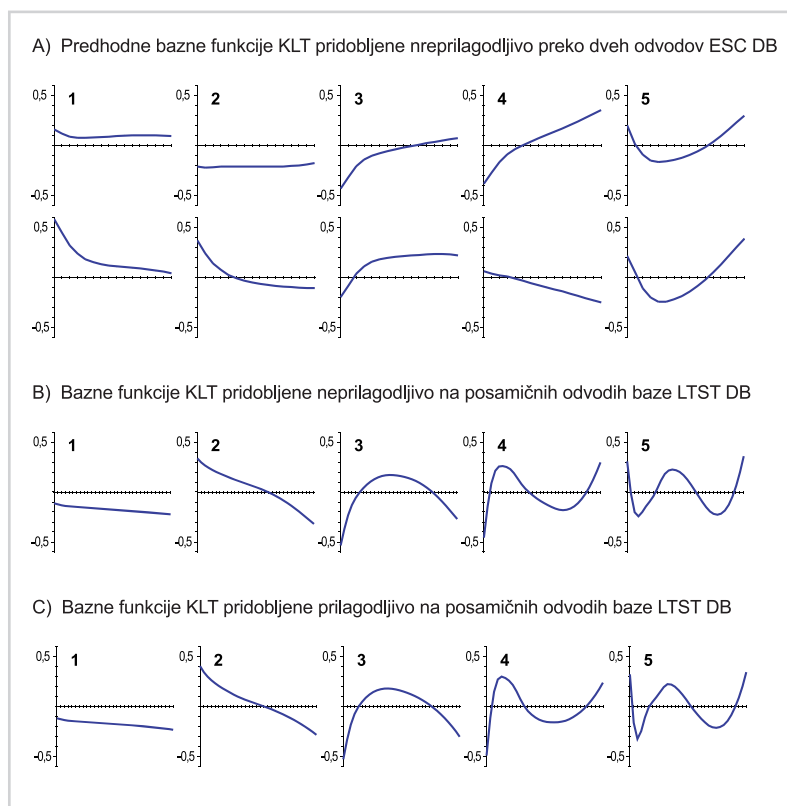
Vzorci, ki jih zajemamo z dinamičnim prilagajanjem dolžine vhodnih vektorjev srčni frekvenci, natančno zajemajo segment ST pri vseh učnih srčnih utripih v podatkovni bazi LTST DB. Z dinamičnim prilagajanjem srčni frekvenci smo iz nabora lastnosti, ki jih želimo zajemati z baznimi funkcijami, izločili pojave, ki predstavljajo pomembne motnje: pojav spremembe dolžine morfoloških elementov zaradi spremenjene srčne frekvence, prisotnost morfologij v zadnjem delu zajetih vzorčnih vektorjev, ki niso več del segmenta ST, in odsotnost določenih morfologij v zadnjem delu segmenta ST, ki ob nižjih srčnih frekvencah niso bile zajete v oknu za zajem vzorcev konstantne dolžine v tradicionalnih algoritmihi. Ti pojavi niso pomembni za analize segmenta ST in ne prestando znatno spreminjajo morfologije, ki bi sicer morale biti zaznane kot enake pri številnih srčnih utripih. Srčna frekvenca se v dolgotrajnih posnetkih EKG namreč tako rekoč ne prestando spreminja. Zato ti pojavi s prisotnostjo v baznih funkcijah pomenijo motnje. Nove bazne funkcije, pridobljene z dinamičnim prilagajanjem srčni frekvenci, bodo tako bolj izostreno zastopale izrazite morfološke lastnosti, ki so posledica dejanskih fizioloških pojavov v njihovem ozadju.

To se pokaže tudi na sliki 4.3, kjer primerjamo prvih pet baznih funkcij treh generacij. Bazne funkcije zadnje generacije (slika 4.3 C.), izdelane s prilagodljivim algoritmom, kažejo večjo izrazitost morfologije v primerjavi z baznimi funkcijami na sliki 4.3 B., ki so bile prav tako pridobljene na podatkovni bazi LTST DB na posamičnih odvodih, a brez dinamičnega prilagajanja dolžine vhodnih vzorcev. To je najbolj izrazito še zlasti pri baznih funkcijah višjih stopenj (četrti ali peta bazna funkcija), ki opisujejo drobnejše morfološke lastnosti.

#### *4.4.1 Ocena časovne zahtevnosti implementacije in časa izvajanja analiz*

Proces izdelave baznih funkcij KLT je sestavljen iz naslednjih operacij:

1. izgradnja kovariančne matrike na osnovi vzorcev segmentov ST celotne podatkovne baze LTST DB, ki vključuje tudi proces dinamičnega prilagajanja vsakega



Slika 4.3

Primerjava prvih petih baznih funkcij treh generacij baznih funkcij KLT za segment ST. A) prikazuje predhodne bazne funkcije KLT za segment ST, pridobljene na podatkovni bazi ESC DB preko dveh odvodov v ločljivosti 16 vzorcev (neprilagodljivo). B) prikazuje bazne funkcije KLT za segment ST, pridobljene na posamičnih odvodih podatkovne baze LTST DB z algoritmom s fiksnim oknom za zajem učnih vzorcev v ločljivosti 32 vzorcev. C) prikazuje zadnjo generacijo baznih funkcij KLT za segment ST, pridobljenih na posamičnih odvodih podatkovne baze LTST DB z novim srčni frekvenci in skladno s slednjo spreminjajoči se dolžini vhodnih vzorcev prilagodljivim algoritmom v ločljivosti 32 vzorcev.

vhodnega vzorčnega vektorja spreminjajoči se srčni frekvenci, proces izračuna srednjih vektorjev razredov vzorcev in proces izračuna srednjega vektorja vseh vzorcev učne množice,

2. izračun baznih funkcij kot lastnih vektorjev kovariančne matrike.

Srednji vektor vseh vzorcev je izračunan preko celotne podatkovne baze LTST DB. Vhodni signal in vektorji vzorcev so v naši implementaciji hranjeni v statičnih poljih v spominu z naključnim dostopom. Dostopi do posamičnih vektorskih komponent se tako izvršijo v konstantnem času. Časovno zahtevnost procesa izračuna srednjega

vektorja vzorcev ocenimo kot

$$T_m = M \cdot T_{am} + S \cdot (T_{IRp} + M \cdot T_{bm}) , \quad T_m = O(S \cdot M) , \quad (4.31)$$

kjer  $S$  pomeni število uporabljenih vzorčnih vektorjev s celotne podatkovne baze LTST DB ( $S = 15.661.886$ ),  $T_{am}$  in  $T_{bm}$  sta oceni konstantnih časov izvajanja pripadajočih aritmetičnih operacij ter branj in zapisovanj podatkov v statičnih podatkovnih poljih,  $T_{IRp}$  je ocenjeni izvajalni čas procesa dinamičnega prilagajanja vzorčnega vektorja glede na srčno frekvenco (poglavje 3.4.1),  $O(\cdot)$  pa pomeni asimptotično časovno zahtevnost.

Iz diagnostičnega kriterija (slika 2.2) izhaja, da najmanjši čas med dvema epizodama znaša 30 s, najmanjše trajanje epizode pa prav tako v skladu s protokolom B znaša 30 s. Tako lahko postavimo, da najkrajša dolžina razredov vzorcev, ki jih oblikujemo, kot opisano v poglavju 4.3, znaša  $t_{min} = 30s$ . Ker število posnetkov v LTST DB znaša  $R = 86$ , en posnetek dolgotrajnega EKG pa tipično traja 24 h, lahko ocenimo, da največje možno število razredov znaša  $L = R \cdot 24 \cdot 3600 \cdot t_{min}^{-1} = 247.680$ . Ugotovitev, da posnetek v skrajnem primeru morda ne vsebuje nobene epizode ali pa je posnetek v celoti epizoda, nas privede do ocene, da najdaljše trajanje enega razreda ne presega 24 h. Če predpostavimo, da je najvišja pričakovana srčna frekvenca 200 utr/min, lahko ocenimo, da največje možno število vzorcev v razredu znaša  $P = 24 \cdot 60 \cdot 200 = 288.000$ . Čas izračuna srednjih vektorjev razredov tako lahko ocenimo kot

$$T_c = L \cdot (M \cdot T_{ac} + P \cdot (T_{IRp} + M \cdot T_{bc})) , \quad T_c = O(L \cdot M) , \quad (4.32)$$

kjer število  $P$  privzamemo kot konstantno,  $T_{ac}$  in  $T_{bc}$  pa sta oceni konstantnih časov izvajanja pripadajočih aritmetičnih operacij ter branj in zapisovanj podatkov v statičnih podatkovnih poljih.

Čas izgradnje kovariančne matrike, implementirane s statičnim podatkovnim poljem  $M \times M$ , na osnovi vseh vzorcev podatkovne baze LTST DB v skladu s formulo (4.28) nato lahko ocenimo kot

$$T_R = T_m + T_c + M^2 \cdot T_{ar} + L \cdot (T_{IRp} + M \cdot T_{br} \cdot (M \cdot T_{cr})) , \quad T_R = O(L \cdot M^2) , \quad (4.33)$$

kjer so  $T_{ar}$ ,  $T_{br}$  in  $T_{cr}$  ocene konstantnih časov izvajanja pripadajočih aritmetičnih operacij ter branj in zapisovanj podatkov v statičnih podatkovnih poljih.



Izračun lastnih vektorjev in lastnih vrednosti kovariančne matrike smo implementirali z algoritmoma [64] Householderjeva redukcija simetrične matrike v tridiagonalno matriko in algoritem QL z implicitnimi pomiki. Asimptotična časovna zahtevnost obeh algoritmov je reda  $O(M^3)$ . Čas izvajanja celotnega procesa pridobitve baznih funkcij za transformacijo KLT  $T_B$  ocenimo kot

$$T_B = T_R + T_V , \quad (4.34)$$

kjer  $T_V$  pomeni oceno izvajalnega časa procesa izračuna lastnih vektorjev in lastnih vrednosti kovariančne matrike. Iz narave naše aplikacije izhaja, da je dimenzionalnost kovariančne matrike in prilagojenih vzorčnih vektorjev  $M$  vselej bistveno manjše število od števila srednjih vektorjev razredov učne množice  $L$ ,  $L \gg M$ . Potem lahko asimptotično časovno zahtevnost  $T_B$  ocenimo kot

$$T_B = O(L \cdot M^2) . \quad (4.35)$$

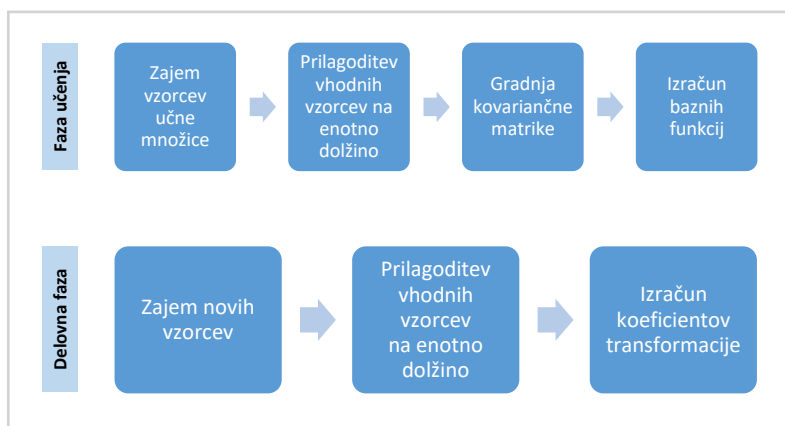
Dejanski izmerjeni čas izvajanja celotnega procesa izdelave baznih funkcij KLT pri  $M = 32$  na strojni opremi razreda x86/x64 znaša 1 h in 41 min pri uporabljenem naboru 15.661.886 vhodnih vzorčnih vektorjev iz podatkovne baze LTST DB. V nadaljnjih procesih izračunavanja transformacije KLT se vselej uporablja po opisanem procesu pridobljen (predračunan) nabor baznih funkcij. Izračun baznih funkcij je časovno razmeroma zahteven proces, vendar je izveden le enkrat in tako ne vpliva na časovno zahtevnost nadaljnjih procesov.

#### 4.5 *Izračun koeficientov transformacije KLT z dinamičnim prilagajanjem dolžine vzorčnih vektorjev*

Z uporabo metod, opisanih v poglavjih 3.4 in 3.5, lahko s transformacijo KLT analiziramo segment ST elektrokardiograma, katerega časovno trajanje se spreminja s spremembami v srčni frekvenci (slika 3.1). Formulo za izračun transformacije KLT (4.23) skladno z (3.22) dopolnimo kot:

$$\mathbf{y} = \Phi_K^\top lRp(\mathbf{x}) , \quad (4.36)$$

kjer je  $lRp(\mathbf{x})$  vektorska funkcija, ki nam poljubni vektor vhodnega vzorca  $\mathbf{x}$  poljubne dolžine v skladu z  $\zeta(r)$  prevzori v ekvivalenten vektor primerno izbrane enotne dolžine



Slika 4.4

Pregled celotnega procesa transformacije KLT z dinamičnim prilagajanjem dolžine vzorčnih vektorjev, osnovane na robustni kovariančni matriki, zgrajeni z vektorji učnih vzorcev različne (prilagodljive) dolžine.

$M$  vzorcev (poglavje 3.4).

Slika 4.4 prikazuje pregled celotnega procesa izračuna koeficientov transformacije KLT z robustno kovariančno matriko in z dinamičnim prilagajanjem dolžine vektorjev vhodnih vzorcev.

#### 4.5.1 Ocena časa izvajanja analiz

Asimptotično časovno zahtevnost procesa izračuna koeficientov transformacije KLT v skladu z izpeljavo (3.24) ocenimo kot  $O(M^2)$ . Četudi namen našega dela v tej fazi ni optimizacija hitrosti delovanja in se za zdaj nismo usmerili k uvajanju hitrih metod za izračun ortogonalnih transformacij, algoritem že v tej obliki na strojni opremi razreda x86/x64 deluje za znaten faktor hitreje od realnega časa. Dejanski izmerjeni čas izračuna prvih devetih koeficientov transformacije KLT pri  $M = 32$  za vse srčne utripe podatkovne baze LTST DB v dveh odvodih, oziroma dvakrat 1991 h in 50 min posnetkov EKG, znaša 1 h in 12 min. Izmerjeni čas izvajanja pri enem posnetku podatkovne baze LTST DB, katerega povprečno trajanje je 23 h in 12 min, pa tako v povprečju znaša 50.23 s.

*Prilagodljiva transformacija  
na osnovi Legendrovih  
polinomov*

Diskretno ortogonalno transformacijo na osnovi Legendrovih polinomov (LPT) za segment ST elektrokardiograma smo zasnovali na podlagi predhodnih opažanj, da že oblike prvih treh baznih funkcij transformacije KLT za segment ST razmeroma dobro ustrezajo trem najpomembnejšim klinično prepoznanim morfološkim lastnostim segmenta ST [10]:

- prisotnost elevacije ali depresije (oziroma spremembe nivoja),
- prisotnost nagiba navzgor ali navzdol ter
- prisotnost ukrivljenosti navzgor ali navzdol.

Kot je razvidno tudi s slike 4.1, prva bazna funkcija KLT tako z obliko, ki je podobna konstantni funkciji, zajema informacijo o spremembah nivoja segmenta ST. Druga bazna funkcija KLT je podobna linearni obliki in tako zajema informacijo o nagibu segmenta ST. Tretja bazna funkcija KLT pa je podobna obliki kvadratne funkcije in tako zajema informacijo o ukrivljenosti segmenta ST elektrokardiograma. A kljub temu so te bazne funkcije le podobne oblikam klinično pomembnih morfoloških lastnosti, kot jih prepoznavajo eksperti kardiologi. Preslikava vrednosti koeficientov KLT v čisto mero prisotnosti ene izmed treh pomembnih morfoloških lastnosti zato ni neposredno izvedljiva. To bi bilo pomembno tako v računalniških analizah kakor tudi za vizualen vpogled v morfologijo segmenta ST, ki bi koristil kliničnim ekspertom pri diagnostiki. Baznim funkcijam KLT se prav tako spreminja predznak, kar še dodatno zaplete enostavnost razumevanja podatkov.

Tę ugotovitve so nas usmerile v razvoj nove ortogonalne baze za transformacijo segmenta ST elektrokardiograma, ki bi združevala dobre lastnosti transformacije KLT in bi hkrati omogočala neposredno preslikavo izračunanih koeficientov v mero prisotnosti treh pomembnih morfoloških lastnosti. Morda tudi ob delni izgubi optimalnosti, ki jo nudi KLT.

Razred ortogonalnih Legendrovih polinomov se je edinstveno izkazal, da združuje vse iskane lastnosti. Prvi trije polinomi so

- konstantna funkcija,
- linearna funkcija in
- kvadratna funkcija

ter tako z matematično natančnostjo ustrezajo navedenim trem klinično prepoznanim pomembnim morfološkim lastnostim segmenta ST. Ker so ortogonalni, jih lahko uporabimo za konstrukcijo baze ortogonalne transformacije.

### 5.1 Zasnova ortogonalne transformacije LPT

Legendrovi polinomi [47] so razred ortogonalnih polinomov, ki so ortogonalni na intervalu  $[-1, 1]$  pri konstantni utežni funkciji  $w(x) = 1$ . Prvih pet Legendrovih polinomov je oblike

$$P_0(x) = 1, \quad (5.1)$$

$$P_1(x) = x, \quad (5.2)$$

$$P_2(x) = \frac{1}{2}(3x^2 - 1), \quad (5.3)$$

$$P_3(x) = \frac{1}{2}(5x^3 - 3x), \quad (5.4)$$

$$P_4(x) = \frac{1}{8}(35x^4 - 30x^2 + 3). \quad (5.5)$$

Njihovi grafi so prikazani na slikah 5.1 in 5.2. Nadaljnje Legendrove polinome lahko generiramo po naslednji rekurzivni enačbi:


$$(j+1)P_{j+1}(x) - (2j+1)xP_j(x) + jP_{j-1}(x) = 0, \quad j = 1, 2, 3, \dots \quad (5.6)$$

$P_j$  predstavlja  $j$ -ti Legendrov polinom. Legendrovi polinomi na intervalu  $[-1, 1]$  ustrezajo naslednji relaciji ortogonalnosti:


$$\int_{-1}^1 P_n(x) P_m(x) dx = \frac{2}{2n-1} \delta_{mn}, \quad n = 1, 2, \dots, \quad m = 1, 2, \dots \quad (5.7)$$

kjer je  $\delta_{mn}$  Kroneckerjeva delta funkcija (3.7).

Legendrovi polinomi tako združujejo iskane lastnosti, kot so zaželeni oblike in ortogonalnost. Ortogonalnost je pomembna lastnost, da so bazne funkcije nekorelirane, kar preprečuje razpršitev informacije med različnimi dimenzijami transformiranega prostora in omogoča tudi reverzibilnost transformacije ter izračun residualnih napak pri aproksimaciji z znižano dimenzijo.

*Slika 5.1*

Grafi prvih šest Legendrovih polinomov ( $P_0$  do  $P_5$ ) na intervalu njihove ortogonalnosti  $[-1, 1]$ .

*Slika 5.2*

Grafi Legendrovih polinomov  $P_6$  do  $P_{11}$  na intervalu njihove ortogonalnosti  $[-1, 1]$ .

Oblike prvih treh Legendrovih polinomov (KONSTANTA, LINEARNA, KVADRATNA FUNKCIJA) tako prinašajo edinstveno možnost neposrednega vpogleda v tri najpomembnejše razrede sprememb morfologije segmenta ST (ELEVACIJA ALI DEPRESIJA, NAGIB, UKRIVLJENOST) preučevanih srčnih utripov v časovnem prostoru neposredno iz prostora značilk (v obliki vizualiziranih časovnih vrst koeficientov transformacije).

Tovrstne skladnosti oblik polinomov s pomembnimi morfologijami segmenta ST elektrokardiograma sicer opazimo tudi pri drugih družinah ortogonalnih polinomov, kot so Čebiševi polinomi, vendar se ti niso izkazali za učinkovite [46]. Ker so ortogonalni pri nekonstantni utežni funkciji, se v ortogonalni formi njihove oblike deformirajo. Legendrovi polinomi so ortogonalni pri konstantni utežni funkciji  $w(x) = 1$ .

Takšne ortogonalne polinome lahko v tabelirani (diskretizirani) obliki učinkovito generiramo s pomočjo naslednjega algoritma [66]:

```

1
2 M = 32; R = 32;
3 x = [-1:2/(M-1):1];
4 k = R-1;
5 [m,n] = size(x);
6 t = zeros(k,n);
7 a = zeros(k,1);
8 b = zeros(k,1);
9 t(1,:) = ones(1,n);
10 t(2,:) = x - sum(x)/n;
11 for i = 2:k
12     a(i+1) = (x*(t(i,:)'.*t(i,:))')/(t(i,:)*t(i,:)');
13     b(i) = t(i,:)*t(i,:)'/t(i-1,:)*t(i-1,:)';
14     t(i+1,:) = (x(:) - a(i+1)).*t(i,:) - b(i).*t(i-1,:);
15 end

```

#### Algoritem 5.1

Algoritem [66] (Matlab) v vrsticah polja  $t$  vrne vrednosti prvih  $R$  ortogonalnih polinomov, izračunane v  $M$  ekvidistantnih točkah. Te točke so enakomerno razporejene na intervalu ortogonalnosti polinomov  $[-1, 1]$  z razmakom  $h = 2/(M-1)$ .

Z algoritmom 5.1 pridobljene diskretizirane ortogonalne polinome, zapisane v stolp-



cih matrike  $\Psi$ , normirano:

$$\Phi_{Lij} = \frac{\psi_{ij}}{\sqrt{\sum_{k=1}^M (\psi_{kj}^2)}}, \quad i = 1, 2, \dots, M, \quad j = 1, 2, \dots, M, \quad (5.8)$$

kjer  $\psi_{ij}$  predstavlja elemente matrike  $\Psi$ . Tako dobljene ortonormalne diskretne funkcije, vsebovane v stolpcih matrike  $\Phi_L = [\Phi_{Lij}]$ , ustrezajo vrednostim v  $M$  ekvidistantnih točkah diskretiziranih normiranih Legendrovih polinomov. Te točke so enakomerno porazdeljene prek intervala ortogonalnosti  $[-1, 1]$ . Slika 5.3 prikazuje prvih pet ortonormalnih baznih funkcij za transformacijo LPT matrike  $\Phi_L$ , v vrstnem redu naraščajoče stopnje polinoma.

## 5.2 Preizkus ortogonalnosti

Zaradi diskretizacije in iterativne narave algoritmov, kjer se numerične napake akumulirajo, je pričakovati določeno stopnjo numerične nestabilnosti in posledično določeno stopnjo izgube ortogonalnosti generiranih baznih funkcij [59, 66]. Od baznih funkcij nove transformacije LPT pričakujemo ortonormalnost,

$$\Phi_L \Phi_L^\top = \mathbf{I}, \quad (5.9)$$

kjer je  $\mathbf{I}$  enotska matrika. To drži do dovolj visoke stopnje natančnosti. Ortonormalnost izračunanih baznih funkcij dimenzije 32 smo preizkusili v smislu odstopanja po (5.9) izračunane enotske matrike od pričakovanih vrednosti njenih komponent (tj. 1 in 0). Za prvih 15 baznih funkcij LPT v matriki  $\Phi_L$  maksimalna napaka diagonalnih elementov izračunane enotske matrike  $\mathbf{I}$  znaša  $4.44 \cdot 10^{-16}$ , pri nediagonalnih elementih  $\mathbf{I}$  pa znaša maksimalna napaka  $6.52 \cdot 10^{-16}$ .

## 5.3 Ortogonalna transformacija LPT

Ortogonalna transformacija LPT preslikuje naključne vektorje  $\mathbf{x} = (\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_M)^\top$  dolžine  $M$  časovnih vzorcev v  $P$ -dimenzionalnem evklidskem prostoru ( $M < P$ ) v vektorje koeficientov  $\mathbf{y} = (\mathbf{y}_1, \mathbf{y}_2, \mathbf{y}_3, \dots, \mathbf{y}_M)^\top$  v prostoru transformacije dimenzije  $M$ , ki ga opredeljujejo bazni vektorji  $\Phi_{Lj}$  iz (5.8). Vektorje koeficientov  $\mathbf{y}$

izrazimo skladno z (3.2), (3.4), (3.12) kot:

$$\mathbf{y} = \Phi_L^\top \mathbf{x} \quad (5.10)$$

in inverzno

$$\mathbf{x} = \Phi_L \mathbf{y} , \quad (5.11)$$

kjer je  $\Phi_L$  ortogonalna matrika, katere stolpci vsebujejo bazne vektorje  $\Phi_{L,j}$  transformacije LPT (tj. diskretizirane Legendrove polinome), komponente vektorja  $\mathbf{y}$  pa so vrednosti koeficientov transformacije  $c_1, c_2, c_3, \dots, c_M$ . Dimenzijo transformiranega prostora lahko poljubno zmanjšamo na dimenzijo  $N$  ( $N \leq M$ ).


Z LPT smo tako dobili diskretno ortogonalno transformacijo, osnovano na medsebojno ortogonalnih Legendrovih polinomih, ki je zaradi svojih specifičnih lastnosti posebno primerna za analizo segmenta ST elektrokardiograma. Legendrovi polinomi so bili za novo transformacijo segmenta ST izbrani načrtno – na eni strani zaradi njihovih podobnosti klinično ugotovljenim pomembnim morfološkim lastnostim in na drugi strani zaradi podobnosti baznim funkcijam KLT (slika 5.3), urejenim po padajočem vrstnem redu pripadajočih lastnih vrednosti. Zato lahko sklepamo, da bo tudi transformacija na osnovi tako skonstruirane ortogonalne baze vsebovala večino morfološke informacije pomembnih razredov vzorcev segmentov ST v začetnih dimenzijah novega transformiranega prostora, če jih uredimo po naraščajoči stopnji pripadajočega Legendrovega polinoma.

#### 5.4 Mahalanobisova razdalja

Če imamo predhodno reprezentativno množico vhodnih vektorjev (npr. učna množica), lahko za mero razlike med poljubnima vektorjema morfoloških značilk v smislu prostorske predstavitve rezultatov transformacije uporabimo Mahalanobisovo razdaljo  $d(\mathbf{y}(j), \mathbf{y}(k))$  med vektorjema koeficientov LPT  $j$ -tega in  $k$ -tega vzorca [7]:

$$d^2(\mathbf{y}(j), \mathbf{y}(k)) = (\mathbf{y}(j) - \mathbf{y}(k))^\top \mathbf{C}^{-1} (\mathbf{y}(j) - \mathbf{y}(k)) , \quad (5.12)$$

kjer  $\mathbf{C}^{-1}$  predstavlja inverz kovariančne matrike vektorjev koeficientov transformacije LPT dane predhodne množice. Matrika  $\mathbf{C}^{-1}$  je diagonalna in simetrična, koeficienti transformacije LPT pa so medsebojno statistično neodvisni. Nediagonalni elementi



Slika 5.3

Primerjava prvih petih Legendrovih polinomov kot baznih funkcij LPT (A) in primera prvih petih baznih funkcij KLT za segment ST (B).

$\mathbf{C}^{-1}$  so zato enaki 0. V razdalji  $d$  sta zato vektorja  $\mathbf{y}(j)$  in  $\mathbf{y}(k)$  normalizirana s pripadajočo standardno deviacijo tako, da je njuna standardna deviacija enaka 1 [7].

### 5.5 Izračun koeficientov transformacije LPT z dinamičnim prilagajanjem dolžine vzorčnih vektorjev

Z uporabo metod, opisanih v poglavjih 3.4 in 3.5, lahko tudi s transformacijo LPT analiziramo segment ST elektrokardiograma, katerega časovno trajanje se spreminja s spremembami v srčni frekvenci (slika 3.1). Formulo za izračun transformacije LPT (5.10) skladno z (3.22) dopolnimo kot:


$$\mathbf{y}_i = \Phi_L^\top lRp(\mathbf{x}_i), \quad (5.13)$$

kjer  $\mathbf{y}_i$  predstavlja vektor koeficientov prilagodljive transformacije LPT  $i$ -tega vhodnega vzorca.  $lRp(\mathbf{x}_i)$  pa je vektorska funkcija, ki nam poljubni vektor vhodnega vzorca  $\mathbf{x}_i$  poljubne dolžine v skladu z  $\zeta(r_i)$  prevzorči v ekvivalenten vektor primerno izbrane enotne dolžine  $M$  vzorcev (poglavje 3.4).

Slika 5.4 prikazuje pregled procesa izračuna koeficientov transformacije LPT z dinamičnim prilagajanjem dolžine vektorjev vhodnih vzorcev.

Slika 5.4

Pregled procesa transformacije LPT z dinamičnim prilagajanjem dolžine vzorčnih vektorjev.



### 5.5.1 Ocena časa izvajanja analiz

Asimptotično časovno zahtevnost procesa izračuna koeficientov transformacije LPT v skladu z izpeljavo (3.24) ocenimo kot  $O(M^2)$ . Četudi namen našega dela v tej fazi ni optimizacija hitrosti delovanja in se za zdaj nismo usmerili k uvajanju hitrih metod za izračun ortogonalnih transformacij, algoritem že v tej obliki na strojni opremi razreda x86/x64 deluje za znaten faktor hitreje od realnega časa. Dejanski izmerjeni čas izračuna prvih devetih koeficientov transformacije LPT pri  $M = 32$  za vse srčne utripe podatkovne baze LTST DB v dveh odvodih, oziroma dvakrat 1991 h in 50 min posnetkov EKG, znaša 1 h in 8 min. Izmerjeni čas izvajanja pri enem posnetku podatkovne baze LTST DB, katerega povprečno trajanje je 23 h in 12 min, pa tako v povprečju znaša 47.44 s.

*Izdelava časovnih vrst  
vektorjev morfoloških značilk*

Razvita metodologija za pripravo časovnih vrst vektorjev morfoloških značilk na osnovi novih prilagodljivih ortogonalnih transformacij KLT in LPT segmenta ST elektrokardiograma vključuje

- več korakov predobdelave vhodnih signalov EKG,
- izločanje nekaterih tradicionalnih diagnostičnih parametrov, kot so denimo podatki o srčni frekvenci in stabilnih referenčnih točkah v srčnih utripih za določitev začetka segmenta ST, ki jih potrebujemo za delovanje prilagodljivih algoritmov,
- določanje dolžine segmenta ST na osnovi srčne frekvence,
- izdelavo kovariančne matrike in baznih funkcij KLT (zgolj v fazi učenja, nad učno množico vhodnih signalov),
- izbiro (zmanjšane) dimenzije transformiranega prostora KLT in LPT,
- izračun prilagodljivih transformacij KLT in LPT segmenta ST elektrokardiograma ter konstrukcija časovnih vrst vektorjev morfoloških značilk.

### *6.1 Predobdelava signalov EKG in izločanje časovnih parametrov*

Visokofrekvenčne motnje v vhodnih signalih EKG izločimo z nizko prepustnim šestpolnim Butterworthovim filtrom z mejno frekvenco 55 Hz, počasno nihanje osnovnega nivoja in druge nizkofrekvenčne motnje pa izločimo z metodo kubične aproksimacije in odštevanja [7]. Sistem Aristotle arrhythmia detector [54] za odkrivanje motenj srčnega ritma izvede detekcijo srčnih utripov in postavitev stabilnih referenčnih točk F v srčnih utripih (slika 2.1) in klasifikacijo srčnih utripov na pravilne in nepravilne. Nepravilne srčne utripe in njihove sosedbe izločimo. Nato z algoritmi v časovnem prostoru [3] izločimo šumne srčne utripe glavnih ugotovljenih virov, kot so mišična aktivnost, premiki elektrod in napačno obravnavani nepravilni srčni utripi (izguba signala, špice, nenadni premiki izhodišča, mišični šum v PQ in ST-T intervalih ter nepravilni utripi, izpušeni v seriji utripov). Tako filtrirani signali kljub temu še vedno vsebujejo določeni delež šumnih srčnih utripov. Te izločimo z algoritmom, ki deluje v prostoru KLT na osnovi predhodnih baznih funkcij, ki so bile pridobljene z osnovnimi algoritmi brez prilagajanja srčni frekvenci na učni množici srčnih utripov iz podatkovne baze

ESC DB [17]. Izločanje šumov v prostoru KLT je robustno in dodatno izloči znaten delež šumnih srčnih utripov, v povprečju  $\overline{N}_{KLT} = 8.51\%$  srčnih utripov, med tem ko predhodni algoritem za izločanje šumov v časovnem prostoru izloči v povprečju  $\overline{N}_{cas} = 0.97\%$  srčnih utripov. Izoelektrični nivo v srčnih utripih določimo z algoritmom, ki poišče najbolj raven interval v signalu EKG pred referenčno točko F v vsakem srčnem utripu in oceni njegov nivo [7].

## 6.2 Izdelava časovnih vrst vektorjev diagnostičnih značilk

Srčno frekvenco ob posamičnih srčnih utripih  $h(j)$ , kjer  $j$  predstavlja indeks srčnega utripa v vhodnih podatkih, določimo z meritvijo dolžine intervala RR med srčnimi utripi, ki jih je detektiral algoritem ARISTOTLE [54]:

$$h(j) = \frac{1}{RR(j)} , \quad (6.1)$$

kjer  $RR(j)$  predstavlja razdaljo na časovni osi točke R  $j$ -tega srčnega utripa do točke R srčnega utripa  $j + 1$ , izraženo v sekundah.

Posamični element časovne vrste nivoja segmenta ST  $s_1(i, j)$ , kjer  $i$  predstavlja indeks posamičnega odvoda EKG, določimo kot:

$$s_1(i, j) = a_{80(60)}(i, j) - z(i, j) , \quad (6.2)$$

kjer je  $a_{80(60)}(i, j)$  nivo v segmentu ST signala EKG  $j$ -tega srčnega utripa pri točki J+80(60),  $z(i, j)$  pa izoelektrični nivo. Kadar je srčna frekvenca  $h(j)$  med 120 in 100 utripi na minuto, točko merjenja nivoja segmenta ST  $a_{80(60)}(i, j)$  linearno prilagajamo med točkama  $F(i, j) + 160$  ms in  $F(i, j) + 120$  ms.

Stopnjo nagiba segmenta ST  $s_s(i, j)$  na osnovi meritve časovnih parametrov tradicionalno določimo kot razliko v nivojih

$$s_s(i, j) = a_{80(60)}(i, j) - a_{20}(i, j) , \quad (6.3)$$

kjer je  $a_{20}(i, j)$  nivo v segmentu ST signala EKG  $j$ -tega srčnega utripa pri točki J+20 ms, izmerjen v točki  $F(i, j) + 60$  ms.

### 6.3 Izbira dimenzije transformiranega prostora KLT in LPT

Preden pripravimo časovne vrste vektorjev morfoloških značilk z novimi algoritmi transformacij KLT in LPT, moramo določiti ustrezno dimenzijo transformiranega prostora – tj. število in tudi izbor morfoloških značilk oziroma koeficientov transformacij, ki jih bomo izračunali. Slednje ustreza izbiri primernega podprostora oziroma primerne podmnožice baznih funkcij transformacij. Kot smo opisali v poglavjih 4 in 5, bomo bazne funkcije pri obeh transformacijah, KLT in LPT, izbirali po njihovem vrstnem redu v matriki transformacije, začenši s prvo.

Določitev primerne dimenzije transformiranega prostora je na eni strani pomembna zaradi tehnične optimizacije, saj gre pri obdelavi dolgotrajnih posnetkov EKG za razmeroma veliko količino podatkov. To pride do izraza še zlasti takrat, ko želimo denimo izvajati različne optimizacijske postopke nad parametri, ki vplivajo na izračun časovnih vrst vektorjev morfoloških značilk (in zato slednje izračunavati večkratno). Na primer optimizacija formule za določanje dolžine segmenta ST na osnovi srčne frekvence oziroma optimizacija rezultatov, na katere slednja lahko vpliva (zmogljivost klasifikacije, ki jo obravnavamo na študiji primera v poglavju 7.3). Po drugi strani pa je ustrezna določitev dimenzije transformiranega prostora pomembna tudi za kakovost rezultatov. Pri ortogonalnih transformacijah se namreč pogosto izkaže, da so informacije o pojavih, ki jih želimo analizirati, vsebovane le v določenih dimenzijah transformiranega prostora (tj. koeficientih transformacije) – pogosto le v nekaj začetnih dimenzijah ali v dimenzijah na določenem intervalu. Preostale dimenzije transformiranega prostora pa vsebujejo podatke, ki niso pomembni za pojave, ki jih želimo analizirati in zato v naših analizah pomenijo motnje.

Pri tem smo se na eni strani naslonili na predhodne časovne vrste vektorjev morfoloških značilk KLT v podatkovni bazi LTST DB, ki so bile izračunane za prvih devet koeficientov. Študija za potrebe razvoja algoritma za izločanje motenj v prostoru transformacije KLT [16] je poleg tega pokazala, da daje najboljše razločevanje med šumnimi in čistimi srčnimi utripi prvih pet koeficientov transformacije KLT. Študija primera klasifikacije med ishemičnimi in neishemičnimi epizodami na osnovi tako transformacije KLT kot transformacije LPT, ki smo jo opravili v okviru tega dela (poglavje 7.3), pa je pri velikem delu klasifikatorjev pokazala najboljše rezultate pri klasifikaciji na osnovi prvih sedem do osem koeficientov transformacije, tako KLT kot LPT (z dodatnimi višjimi koeficienti pa natančnost klasifikacije pade). Nekateri klasifikatorji dajo nekoliko



boljše rezultate z devetimi koeficienti kot z osmimi, vendar je že od šestega koeficienta naprej izrazit trend zmanjševanja izboljšave z dodatnim koeficientom (tj. izboljšava klasifikacijske točnosti manj kot 0.5% pri dodanem devetem koeficientu). Na podlagi teh ugotovitev smo zaključili, da bo tudi za naše nadaljnje delo ustrezna dimenzija transformiranega prostora devet (koeficientov transformacij KLT in LPT).

#### 6.4 Izdelava časovnih vrst vektorjev morfoloških značilk s prilagodljivimi KLT in LPT na posamičnih odvodih LTST DB

Za izdelavo časovnih vrst vektorjev značilk s prilagodljivima transformacijama KLT in LPT za vsak izoelektrično korigiran segment ST v vsakem srčnem utripu  $j$  podatkovne baze LTST DB za vsak odvod  $i$  izračunamo vektor značilk KLT  $\mathbf{s}'_K(i, j)$  dolžine  $N$  koeficientov ( $N = 9$ ) in vektor značilk LPT  $\mathbf{s}'_L(i, j)$  dolžine  $N$  koeficientov ( $N = 9$ ):

$$\mathbf{s}'_K(i, j) = \Phi_K^\top \text{LRp}(\mathbf{x}(i, j)) , \quad (6.4)$$

$$\mathbf{s}'_L(i, j) = \Phi_L^\top \text{LRp}(\mathbf{x}(i, j)) , \quad (6.5)$$

kjer je  $\Phi_K$  ortogonalna matrika transformacije KLT, sestavljena iz baznih funkcij KLT enotne dolžine  $M$ ,  $\Phi_L$  ortogonalna matrika transformacije LPT, sestavljena iz baznih funkcij LPT enotne dolžine  $M$ ,  $\mathbf{x}(i, j)$  pa je vektor vhodnega vzorca segmenta ST, sestavljen iz  $M_j$  časovnih vzorcev izvirnega signala EKG, vzorčenega s frekvenco vzorčenja 250 Hz. Časovne vzorce segmentov ST iz vhodnega signala EKG zajemamo v vhodne vektorje od točke  $F(i, j) + 40$  ms do točke  $F(i, j) + 40 + ST_{h(i, j)}$  ms, kjer nam  $i$  predstavlja indeks odvoda v posnetku LTST DB,  $j$  predstavlja zaporedni indeks posamičnega srčnega utripa,  $F(i, j)$  pa predstavlja stabilno referenčno točko v vsakem srčnem utripu, kot jih je postavil sistem za odkrivanje motenj srčnega ritma ARISTO-TLE v predhodnih fazah predobdelave (poglavje 6.1).  $ST_{h(i, j)}$  predstavlja dolžino segmenta ST, kot je za srčno frekvenco pri posamičnem srčnem utripu  $h(j)$  definirano v tabeli 3.3. Dolžina vhodnih vektorjev časovnih vzorcev  $M_j$  se tako za vsak posamični srčni utrip spremeni in je enaka dolžini segmenta ST v enotah časovnih vzorcev iz tabele 3.3 pri srčni frekvenci  $h(j)$  posamičnega vektorja, zajetega iz srčnega utripa  $j$ .  $\text{LRp}(\mathbf{x}(i, j))$  predstavlja vektorsko funkcijo, ki nam poljubni vektor vhodnega vzorca  $\mathbf{x}(i, j)$  poljubne dolžine v skladu z  $ST_{h(i, j)}$ , prevzorči v ekvivalenten vektor primerno izbrane enotne dolžine  $M$  vzorcev (poglavje 3.4). Vhodne vektorje časovnih vzorcev

tako prilagodimo izbrani enotni dolžini  $M = 32$  časovnih vzorcev. Dolžina je bila izbrana skladno z določili predhodnih algoritmov, ki so za jemanje časovnih vzorcev segmenta ST ocenili njegovo dolžino na 128 ms [17]. Upoštevaajoč frekvenco vzorčenja, ki so jo v LTST DB določili eksperti kardiologi ob njenem razvoju tako, da ustrezno zajame vse klinično pomembne morfološke značilnosti in znaša 250 Hz, enotna dolžina vhodnih vektorjev pa znaša  $M = 32$  časovnih vzorcev (poglavje 3.4).

Končno obliko časovnih vrst vektorjev morfoloških značilk KLT in LPT ( $s_K(i, j)$  in  $s_L(i, j)$ ) dobimo tako, da koeficiente vektorjev morfoloških značilk KLT in LPT ( $s'_{K,k}(i, j)$  in  $s'_{L,k}(i, j)$ ) normaliziramo z njihovimi standardnimi deviacijami  $\rho_k$  (za koeficiente transformacije KLT) in  $\theta_k$  (za koeficiente transformacije LPT), ki smo jih izračunali preko celotne učne množice (tj. celotne podatkovne baze LTST DB):

$$s_{K,k}(i, j) = \frac{s'_{K,k}(i, j)}{\rho_k}, \quad k = 1, 2, 3, \dots, N, \quad (6.6)$$

$$s_{L,k}(i, j) = \frac{s'_{L,k}(i, j)}{\theta_k}, \quad k = 1, 2, 3, \dots, N. \quad (6.7)$$

Takšno normaliziranje poudari (ojača) drobnejše lastnosti, ki jih zajemajo bazne funkcije višjih redov, ki imajo praviloma nižje standardne deviacije. Vsak vektor morfoloških značilk je tako normaliziran, da pričakovana standardna deviacija vsake komponente pridobljenih vektorjev morfoloških značilk znaša 1.

Standardne deviacije  $\rho_k$  in  $\theta_k$  smo izračunali na osnovi 7.830.943 čistih srčnih utripov podatkovne baze LTST DB, kot smo jih pripravili za izdelavo kovariančne matrike za izračun baznih funkcij KLT. Tabela 6.1 prikazuje vrednosti prvih devetih standardnih deviacij ( $\rho_k$  in  $\theta_k$ ) koeficientov časovnih vrst vektorjev morfoloških značilk KLT in LPT. Magnitude standardnih deviacij KLT so v padajočem vrstnem redu, kar se sklada z definicijo transformacije (poglavje 4). Magnitude standardnih deviacij LPT, urejenih naraščajoče po redu pripadajočega Legendrovega polinoma, prav tako kažejo padajoč trend. To se sklada s pričakovanji, saj so bili Legendrovi polinomi kot osnova za bazo transformacije izbrani namensko zaradi podobnosti baznim funkcijam KLT in hkrati najizrazitejšim lastnostim segmenta ST.

Normaliziranje koeficientov nam prav tako omogoča izraziti mero razlike med vektorji morfoloških značilk v smislu Mahalanobisove razdalje. Posebno uporabna je ča-

Tabela 6.1

Standardne deviacije časovnih vrst prvih devetih koeficientov vektorjev morfoloških značilk KLT ( $\rho_k$ ) in prvih devetih koeficientov vektorjev morfoloških značilk LPT ( $\theta_k$ ), pridobljenih na podatkovni bazi LTST DB z uporabo prilagodljivih transformacij na osnovi  $\Phi_K$  in  $\Phi_L$ . Vrednosti so v enotah [20 enot = 100  $\mu$ V].

$k$	1	2	3	4	5	6	7	8	9
$\rho_k$	116.24	38.62	20.43	10.41	6.32	5.41	5.19	4.92	4.49
$\theta_k$	115.04	41.32	20.59	11.04	8.13	6.62	5.60	5.15	4.59

sojna vrsta  $d(i, j)$ , ki jo izračunamo kot Mahalanobisovo razdaljo med vektorjem morfoloških značilk  $j$ -tega srčnega utripa in vektorjem morfoloških značilk prvega (izhodiščnega) srčnega utripa v posnetku EKG:

$$d_K^2(i, j) = \sum_{k=1}^{N_D} (s_{K, k}(i, j) - s_{K, k}(i, 1))^2, \quad (6.8)$$

$$d_L^2(i, j) = \sum_{k=1}^{N_D} (s_{L, k}(i, j) - s_{L, k}(i, 1))^2, \quad (6.9)$$

kjer sta  $s_{K, k}(i, 1)$  in  $s_{L, k}(i, 1)$  vektorja morfoloških značilk prvega srčnega utripa v posnetku EKG,  $N_D$  pa je dimenzionalnost Mahalanobisove razdalje.

Na takšen način na osnovi kompleksnejše večdimenzionalne časovne vrste pridobimo strnjeno enodimenzionalno časovno vrsto značilk, uporabno za poenostavljeno vizualno opazovanje morfoloških sprememb in tudi za nadaljnje računalniške analitske postopke.

Tako smo izdelali nove časovne vrste vektorjev morfoloških značilk na osnovi srčni frekvenci prilagodljivih ortogonalnih transformacij KLT in LPT segmenta ST elektrokardiograma. Nove morfološke časovne vrste so bile izdelane za prvih devet koeficientov KLT in prvih devet koeficientov LPT za vse odvode vseh posnetkov EKG podatkovne baze LTST DB. Celotna podatkovna baza LTST DB je javno dostopna na osrednjem spletnem portalu za fiziološke podatkovne baze Physionet [53] kot ena izmed temeljnih podatkovnih baz fizioloških posnetkov na področju EKG (tj. "Class 1; core"). Objava novih časovnih vrst vektorjev morfoloških značilk prilagodljivih KLT in LPT v okviru LTST DB je v času nastanka tega dela v pripravi. Časovne

vrste prvih devetih koeficientov KLT  $s'_{K,k}(i,j)$  in prvih devetih normaliziranih koeficientov KLT  $s_{K,k}(i,j)$  s pripadajočimi residualnimi napakami so shranjene v datotekah *sYYYYZ.aks* in *sYYYYZ.anks* podatkovne baze LTST DB. Časovne vrste prvih devetih koeficientov LPT  $s'_{L,k}(i,j)$  in prvih devetih normaliziranih koeficientov LPT  $s_{L,k}(i,j)$  s pripadajočimi residualnimi napakami so shranjene v datotekah *sYYYYZ.aloc* in *sYYYYZ.anoc* podatkovne baze LTST DB. Primeri vizualizacije trendov časovnih vrst izbranih posnetkov LTST DB so razvidni na slikah 7.7 in 7.8. X v imenu datotek pomeni število odvodov, ki jih vsebuje posamični posnetek (2 ali 3), YYY je številka pacienta, pri katerem je bil posnetek EKG zajet, Z pa predstavlja številko posnetka pri tem pacientu.

Novе časovne vrste vektorjev morfoloških značilk na osnovi novih algoritmov brez prilagajanja srčni frekvenci za prvih devet koeficientov KLT in prvih devet koeficientov LPT za vse odvode vseh posnetkov EKG podatkovne baze LTST DB so že objavljene na portalu Physionet (<http://www.physionet.org/physiobank/database/ltstadb/>). Časovne vrste prvih devetih koeficientov KLT  $s'_{K,k}(i,j)$  in prvih devetih normaliziranih koeficientov KLT  $s_{K,k}(i,j)$  s pripadajočimi residualnimi napakami so shranjene v datotekah *sYYYYZ.kls* in *sYYYYZ.nks* podatkovne baze LTST DB. Časovne vrste prvih devetih koeficientov LPT  $s'_{L,k}(i,j)$  in prvih devetih normaliziranih koeficientov LPT  $s_{L,k}(i,j)$  s pripadajočimi residualnimi napakami so shranjene v datotekah *sYYYYZ.loc* in *sYYYYZ.noc* podatkovne baze LTST DB.

Datoteke časovnih vrst vektorjev morfoloških značilk so zapisane v besedilni obliki ASCII. Podatki so urejeni v stolpcih, ločenih z ločilnim znakom presledek. Vsaka vrstica datoteke predstavlja podatke ob posamičnem srčnem utripu ob časovnem indeksu srčnega utripa v posnetku, ki je zapisan v prvem stolpcu. Stolpci si sledijo v naslednjem vrstnem redu:

1. stolpec: časovni indeks (Aristotle-jeva stabilna referenčna točka utripa)

2. stolpec: 1. koeficient za 1. odvod (pomnožen s 100)

3. stolpec: 2. koeficient za 1. odvod (pomnožen s 100)

4. stolpec: 3. koeficient za 1. odvod (pomnožen s 100)

5. stolpec: 4. koeficient za 1. odvod (pomnožen s 100)

- 6. stolpec: 5. koeficient za 1. odvod (pomnožen s 100)
- 7. stolpec: 6. koeficient za 1. odvod (pomnožen s 100)
- 8. stolpec: 7. koeficient za 1. odvod (pomnožen s 100)
- 9. stolpec: 8. koeficient za 1. odvod (pomnožen s 100)
- 10. stolpec: 9. koeficient za 1. odvod (pomnožen s 100)

- 11. stolpec: residualna napaka, prvih 1 koeficientov, za 1. odvod
- 12. stolpec: residualna napaka, prvih 2 koeficientov, za 1. odvod
- 13. stolpec: residualna napaka, prvih 3 koeficientov, za 1. odvod
- 14. stolpec: residualna napaka, prvih 4 koeficientov, za 1. odvod
- 15. stolpec: residualna napaka, prvih 5 koeficientov, za 1. odvod
- 16. stolpec: residualna napaka, prvih 6 koeficientov, za 1. odvod
- 17. stolpec: residualna napaka, prvih 7 koeficientov, za 1. odvod
- 18. stolpec: residualna napaka, prvih 8 koeficientov, za 1. odvod
- 19. stolpec: residualna napaka, prvih 9 koeficientov, za 1. odvod

- 20. stolpec: 1. koeficient za 2. odvod (pomnožen s 100)
- 21. stolpec: 2. koeficient za 2. odvod (pomnožen s 100)
- 22. stolpec: 3. koeficient za 2. odvod (pomnožen s 100)
- 23. stolpec: 4. koeficient za 2. odvod (pomnožen s 100)
- 24. stolpec: 5. koeficient za 2. odvod (pomnožen s 100)
- 25. stolpec: 6. koeficient za 2. odvod (pomnožen s 100)
- 26. stolpec: 7. koeficient za 2. odvod (pomnožen s 100)
- 27. stolpec: 8. koeficient za 2. odvod (pomnožen s 100)
- 28. stolpec: 9. koeficient za 2. odvod (pomnožen s 100)

- 29. stolpec: residualna napaka, prvih 1 koeficientov, za 2. odvod
- 30. stolpec: residualna napaka, prvih 2 koeficientov, za 2. odvod
- 31. stolpec: residualna napaka, prvih 3 koeficientov, za 2. odvod
- 32. stolpec: residualna napaka, prvih 4 koeficientov, za 2. odvod
- 33. stolpec: residualna napaka, prvih 5 koeficientov, za 2. odvod
- 34. stolpec: residualna napaka, prvih 6 koeficientov, za 2. odvod

35. stolpec: residualna napaka, prvih 7 koeficientov, za 2. odvod  
 36. stolpec: residualna napaka, prvih 8 koeficientov, za 2. odvod  
 37. stolpec: residualna napaka, prvih 9 koeficientov, za 2. odvod

Datoteke s časovnimi vrstami posnetkov s tremi odvodi (*s3YYYZ.\**) vsebujejo nadaljnje stolpce 38–55:

38. stolpec: 1. koeficient za 3. odvod (pomnožen s 100)  
 39. stolpec: 2. koeficient za 3. odvod (pomnožen s 100)  
 40. stolpec: 3. koeficient za 3. odvod (pomnožen s 100)  
 41. stolpec: 4. koeficient za 3. odvod (pomnožen s 100)  
 42. stolpec: 5. koeficient za 3. odvod (pomnožen s 100)  
 43. stolpec: 6. koeficient za 3. odvod (pomnožen s 100)  
 44. stolpec: 7. koeficient za 3. odvod (pomnožen s 100)  
 45. stolpec: 8. koeficient za 3. odvod (pomnožen s 100)  
 46. stolpec: 9. koeficient za 3. odvod (pomnožen s 100)

47. stolpec: residualna napaka, prvih 1 koeficientov, za 3. odvod  
 48. stolpec: residualna napaka, prvih 2 koeficientov, za 3. odvod  
 49. stolpec: residualna napaka, prvih 3 koeficientov, za 3. odvod  
 50. stolpec: residualna napaka, prvih 4 koeficientov, za 3. odvod  
 51. stolpec: residualna napaka, prvih 5 koeficientov, za 3. odvod  
 52. stolpec: residualna napaka, prvih 6 koeficientov, za 3. odvod  
 53. stolpec: residualna napaka, prvih 7 koeficientov, za 3. odvod  
 54. stolpec: residualna napaka, prvih 8 koeficientov, za 3. odvod  
 55. stolpec: residualna napaka, prvih 9 koeficientov, za 3. odvod

### 6.5 Ocena časa izvajanja analiz

Četudi namen našega dela v tej fazi ni optimizacija hitrosti delovanja in se za zdaj nismo usmerili k uvajanju hitrih metod za izračun ortogonalnih transformacij, sistem že v tej obliki na strojni opremi razreda x86/x64 deluje za znaten faktor hitreje od realnega časa. Predobdelava signalov EKG zajema nizko prepustno filtriranje s šestpolnim

Butterworthovim filtrom, odkrivanje motenj srčnega ritma in detekcijo srčnih utripov, postavitve stabilnih referenčnih točk F v srčnih utripih in klasifikacijo srčnih utripov na pravilne in nepravilne s sistemom Aristotle arrhythmia detector, izločanje počasnega nihanja osnovnega nivoja in drugih nizkofrekvenčnih motenj z metodo kubične aproksimacije in odštevanja ter izločanje šumnih srčnih utripov v prostoru transformacije KLT. Dejanski izmerjeni čas predobdelave signalov EKG in izračuna diagnostičnih značilik (srčna frekvenca, nivo in nagib segmenta ST) za vse srčne utripe podatkovne baze LTST DB v dveh odvodih, oziroma dvakrat 1991 h in 50 min posnetkov EKG, znaša 1 h in 23 min. Izmerjeni čas izvajanja pri enem posnetku podatkovne baze LTST DB, katerega povprečno trajanje je 23 h in 12 min, pa tako v povprečju znaša 57.9 s. Dejanski izmerjeni čas izračuna prvih devetih koeficientov transformacije za vse predobdelane srčne utripe podatkovne baze LTST DB v dveh odvodih pa znaša 1 h in 12 min s transformacijo KLT oziroma 1 h in 8 min s transformacijo LPT. Povprečni izmerjeni čas izvajanja pri enem predobdelanem posnetku podatkovne baze LTST DB tako znaša 50.23 s z uporabo transformacije KLT oziroma 47.44 s z uporabo transformacije LPT.

Skupni izmerjeni čas celotnega procesa izdelave časovnih vrst vektorjev morfoloških značilik v dveh odvodih nad celotno podatkovno bazo LTST DB znaša 2 h in 35 min s transformacijo KLT oziroma 2 h in 31 min s transformacijo LPT. Skupni izmerjeni čas izvajanja pri enem posnetku podatkovne baze LTST DB, katerega povprečno trajanje je 23 h in 12 min, pa tako v povprečju znaša 1 min in 48 s z uporabo transformacije KLT oziroma 1 min in 45 s z uporabo transformacije LPT. Če privzamemo srednjo vrednost meritev časa izvajanja z uporabo bodisi transformacije KLT bodisi transformacije LPT, lahko ocenimo, da povprečni čas izvajanja na eno uro posnetka EKG v dveh odvodih znaša 4.60 s.





# *Evaluacija novih algoritmov in metod*


7

Želimo oceniti zmogljivost novih metod za prilagodljivo ocenjevanje morfologij segmenta ST elektrokardiograma z ortogonalnimi transformacijami tako za namene eksperimentalnega (vizualnega) preučevanja in diagnostike kot za namene avtomatskih metod (avtomatska detekcija in klasifikacija). Novo (prilagodljivo) transformacijo LPT želimo primerjati s prav tako izboljšano transformacijo KLT (prilagodljiv algoritem za izračun baznih funkcij) in ugotoviti njune morebitne posamične prednosti za različne naloge pri analizah in avtomatskih metodah na osnovi segmenta ST elektrokardiograma. Želimo oceniti tudi prednosti, ki jih prinaša algoritem za prilagodljivo gradnjo kovariante matrike za izračun baznih funkcij KLT. V te namene smo izvedli študijo karakterizacije ishemičnih in neishemičnih sprememb v morfologiji segmenta ST elektrokardiograma z novimi prilagodljivimi morfološkimi časovnimi vrstami KLT in LPT. Zmogljivost novih metod za ocenjevanje morfoloških značilnosti za namene avtomatskih analiz in detekcije analiziramo v študiji na primeru klasifikacije med ishemičnimi in neishemičnimi epizodami sprememb v morfologiji segmenta ST z izbranimi klasifikatorji okolja MathWorks MATLAB Statistics and Machine Learning Toolbox.


### *7.1 Algoritem za dinamično ocenjevanje dolžine segmenta ST na osnovi srčne frekvence*

Ker dosedanja algoritmi pri svojem delovanju niso upoštevali spreminjajoče se dolžine segmenta ST ob spreminjajoči se srčni frekvenci, je virov s tega področja dokaj malo. Prav tako ne obstaja baza posnetkov EKG, v kateri bi bile označene dolžine segmenta ST. Zato smo funkcijo za izračun dolžine segmenta ST na osnovi srčne frekvence, ki smo jo razvili (tabela 3.3), preverili empirično v študiji na primerih iz podatkovne baze LTST DB. Delovanje razvite funkcije smo ocenjevali na razponu srčnih utripov različnih srčnih frekvenc od ekstremno nizkih (28 utripov na minuto) do povprečnih (60 do 100 utripov na minuto) ter nadpovprečno visokih (nad 140 utripov na minuto).

Na slikah 7.1 do 7.6 je prikazanih nekaj primerov elektrokardiogramov srčnih utripov iz podatkovne baze LTST DB. Na njihova območja segmenta ST, kot ga definira kardiologija (območje, ki se začne ob prevoju kolena J in zaključuje pred valom T [7]), postavljamo ocene dolžin segmenta ST (potemnjene intervali), kot nam jih določi razvita funkcija za izračun dolžine segmenta ST v odvisnosti od srčne frekvence. Kot prikazujejo primeri na navedenih slikah, nova funkcija zanesljivo sledi dolžini segmenta ST ob različnih srčnih frekvencah od tako rekoč nepričakovano nizkih do najvišjih srčnih

*Slika 7.1*


Primer EKG srčnega utripa s srčno frekvenco 164 utripov v minuti iz prvega odvoda posnetka s20541 podatkovne baze LTST DB ob času 22:24:28. Po razviti funkciji (tabela 3.3) ocenjena dolžina segmenta ST (76 ms pri srčni frekvenci 164 utripov v minuti) je prikazana nad območjem segmenta ST v elektrokardiogramu srčnega utripa na sliki (potemnjeni interval).

*Slika 7.2*

Primer EKG srčnega utripa s srčno frekvenco 142 utripov v minuti iz prvega odvoda posnetka s20621 podatkovne baze LTST DB ob času 23:20:18. Po razviti funkciji (tabela 3.3) ocenjena dolžina segmenta ST (84 ms pri srčni frekvenci 142 utripov v minuti) je prikazana nad območjem segmenta ST v elektrokardiogramu srčnega utripa na sliki (potemnjeni interval).


Slika 7.3

Primer EKG srčnega utripa s srčno frekvenco 98 utripov v minuti iz prvega odvoda posnetka s200511 podatkovne baze LTST DB ob času 17:45:00. Po razviti funkciji (tabela 3.3) ocenjena dolžina segmenta ST (116 ms pri srčni frekvenci 98 utripov v minuti) je prikazana nad območjem segmenta ST v elektrokardiogramu srčnega utripa na sliki (potemnjeni interval).




Slika 7.4

Primer EKG srčnega utripa s srčno frekvenco 60 utripov v minuti iz drugega odvoda posnetka s200111 podatkovne baze LTST DB ob času 10:30:02. Po razviti funkciji (tabela 3.3) ocenjena dolžina segmenta ST (140 ms pri srčni frekvenci 60 utripov v minuti) je prikazana nad območjem segmenta ST v elektrokardiogramu srčnega utripa na sliki (potemnjeni interval).



*Slika 7.5*

Primer EKG srčnega utripa s srčno frekvenco 45 utripov v minuti iz prvega odvoda posnetka s203311 podatkovne baze LTST DB ob času 10:30:01. Po razviti funkciji (tabela 3.3) ocenjena dolžina segmenta ST (152 ms pri srčni frekvenci 45 utripov v minuti) je prikazana nad območjem segmenta ST v elektrokardiogramu srčnega utripa na sliki (potemnjeni interval).

*Slika 7.6*

Primer EKG srčnega utripa s srčno frekvenco 28 utripov v minuti iz prvega odvoda posnetka s203311 podatkovne baze LTST DB ob času 13:36:47. Po razviti funkciji (tabela 3.3) ocenjena dolžina segmenta ST (156 ms pri srčni frekvenci 28 utripov v minuti) je prikazana nad območjem segmenta ST v elektrokardiogramu srčnega utripa na sliki (potemnjeni interval).

frekvenc, kar jih vsebujejo primeri v podatkovni bazi LTST DB. Tako sklepamo, da bo nova funkcija tudi na neznanih signalih EKG (z znano srčno frekvenco) zanesljivo določala dolžino segmenta ST in da jo zato lahko uporabimo v novih algoritmihi.

Ob primerih z višjimi srčnimi frekvencami na slikah 7.1 in 7.2 je tudi dobro razvidno, da tradicionalni pristop s konstantno dolžino segmenta ST 120 ms (in prav tako pri točkovnem merjenju diagnostičnih parametrov ob fiksni časovni točki) v analizi zajema velik del neželene morfologije vala T. Prav tako pa nam primeri ob nizkih srčnih frekvencah na slikah 7.5 in 7.6 kažejo, da fiksno okno za jemanje vzorcev širine 120 ms pomembnega dela signala (ob koncu) segmenta ST sploh ne zajame.

## 7.2 Opisovanje oblik prehodnih epizod segmenta ST elektrokardiograma s prilagodljivimi KLT in LPT

Med izdelavo oznak prehodnih epizod odstopanj segmenta ST elektrokardiograma v podatkovni bazi LTST DB so eksperti kardiologi definirali dva razreda sprememb segmenta ST z naslednjimi značilnostmi [10]:

1. PREHODNE ISHEMIČNE SPREMEMBE SEGMENTA ST, ki jih zaznamuje tipičen trikotni vzorec spremembe nivoja segmenta ST (slika 2.2), prisotna je lahko tudi (lahko pa tudi ne) sprememba srčne frekvence, dodatne klinične informacije pa nakazujejo ishemijo. Takšne epizode se v morfologiji segmenta ST tipično odražajo kot depresija ali elevacija oziroma izrazita sprememba nivoja segmenta ST, horizontalna sploščitev segmenta ST in nagib navzdol ali ukrivljenost.
2. PREHODNE NEISHEMIČNE SPREMEMBE SEGMENTA ST, ki so prav tako zaznamovane s trikotnim vzorcem spremembe nivoja segmenta ST, a z obvezno izrazito spremembo srčne frekvence in dodatnimi informacijami, da preiskovančeva klinična slika ne nakazuje ishemije. Tipične spremembe v morfologiji segmenta ST ob prehodnih neishemičnih epizodah so depresija kolena J s pozitivnim nagibom, pomik vala T proti segmentu ST, paralelni premik segmenta ST (v primerjavi z referenco) in povišanje vala T.

Kot prikazujemo v nadaljevanju, lahko tovrstne spremembe v morfologiji znatno boljše spremljamo preko časovnih vrst morfoloških značilk oziroma koeficientov ustrezno zasnovanih ortogonalnih transformacij, kakršni sta KLT in LPT, v primerjavi s tradicionalnimi morfološkimi parametri, pridobljenimi z neposrednimi točkovnimi

meritvami v časovnem prostoru [68]. Še zlasti pridejo do izraza prednosti takšnega spremljanja spreminjajoče se morfologije preučevanih pojavov preko časovnih vrst pri analizi večjih količin podatkov, kot denimo pri analizi sprememb segmenta ST v dolgotrajnih posnetkih EKG. Na enem samem prikazu je možno spremljati dinamiko morfologije preko več ur, kar bi s tradicionalnim pregledovanjem posamičnih srčnih utripov tipično pomenilo analizo več tisoč utripov.


Sliki 7.7 in 7.8 prikazujeta primer vizualizacije triurnih trendov časovnih vrst vektorjev morfoloških značilk segmenta ST z dinamičnim prilagajanjem srčni frekvenci, dolgotrajnega posnetka elektrokardiograma v podatkovni bazi LTST DB. Vidni so paralelni pomiki segmenta ST (neishemična sprememba nivoja segmenta ST) in ishemične epizode sprememb segmenta ST. V prikazanih srčnih utripih A in B, zajetih pred in po izrazitem pomiku segmenta ST, se jasno vidijo morfološke spremembe segmenta ST (oznaka "ST<sub>D</sub>" na slikah srčnih utripov spodaj). V predelu segmenta ST lahko opazimo dvig nivoja segmenta ST in pozitivni nagib. Ti morfološki spremembi se dobro pokažeta v časovnih diagnostičnih morfoloških parametrih (zgoraj) in prvih dveh koeficientih časovnih vrst KLT (slika 7.7, KLT<sub>1</sub> in KLT<sub>2</sub>) in LPT (slika 7.8, LPT<sub>1</sub> in LPT<sub>2</sub>). Toda v prostoru KLT naravo sprememb težje razberemo, ker preslikava z morfološkimi lastnostmi ni tako neposredna kot pri LPT (in časovnih morfoloških parametrih). Vizualizacija časovnih vrst tretjega koeficienta KLT<sub>3</sub> in LPT<sub>3</sub> pokaže, kako tretji koeficient omogoča dobro ocenjevanje klinično pomembne morfološke značilnosti ukrivljanja. Po pričakovanju LPT omogoča jasnejšo zaznavo ukrivljanja zaradi čiste oblike bazne funkcije na osnovi matematične kvadratne funkcije, in sicer v primerjavi s KLT. Časovni parametri ukrivljenosti sploh ne zaznavajo.

Prav tako tretji srčni utrip (C) na slikah 7.7 in 7.8 v ekstremu ishemične epizode kaže izrazito depresijo, izrazit nagib navzdol in rahlo negativno ukrivljenost. Tri značilne spremembe lahko dobro opazujemo v trendih prvih treh časovnih vrst LPT (ob oznaki "C"), medtem ko dinamika časovnih vrst KLT prav tako nakazuje izrazite morfološke spremembe, a je težje razbrati njihov diagnostični pomen v smislu oblik segmenta ST v časovnem prostoru.


Sliki 7.9 in 7.10 prikazujeta primera potekov prehodne ishemične in prehodne neishemične epizode segmenta ST. Na sliki 7.9 je viden primer ishemične depresije (znižanja nivoja) in ukrivljanja segmenta ST. Na sliki 7.10 je prikazan primer neishemičnega povišanja nivoja segmenta ST zaradi pomika vala T proti kompleksu QRS. Spremembe v morfologijah, ki jih zaznamo, ustrezajo oblikam baznih funkcij (slika 5.3). Kate-

## Slika 7.7

Vizualizacija trendov pridobljenih časovnih vrst vektorjev diagnostičnih značilk in morfoloških značilk KLT segmenta ST **Z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI**, za posnetek s20421 podatkovne baze LTST DB od časa 04:00 [hh:mm] do časa 07:00. Vidni so neishemični paralelni pomiki segmenta ST in prehodne ishemične epizode segmenta ST. *Od zgoraj navzdol:* srčna frekvenca  $h(j)$  v [utrr/min]; v časovnem prostoru izmerjeni nivo segmenta  $s_1(2, j)$  in v časovnem prostoru izmerjeni nagib segmenta  $s_5(2, j)$  (navpična os:  $100\mu\text{V}/\text{razdelek}$ ); eksperto označene prehodne epizode segmenta ST (ozki pravokotniki); vizualizirane časovne vrste prvih petih koeficientov KLT segmenta ST  $s_{K_i}(2, j)$  s pripadajočo Mahalanobisovo razdaljo  $d_{K_i}(2, j)$  (navpična os:  $1\sigma/\text{razdelek}$ ). *Spodaj:* Slike srčnih utripov ob oznakah A, B in C v časovnih vrstah; pred paralelnim pomikom [04:13:26.176], po paralelnem pomiku [04:43:30.416] in v ekstremu ishemične epizode segmenta ST [06:30:08.056]. Na srčnih utripih so označeni segment ST ("ST<sub>D</sub>"), izoelektrični nivo ("ISO"), koleno J in točka merjenja nivoja segmenta ST v časovnem prostoru ("F+120 ms").








**Slika 7.8**

Vizualizacija trendov pridobljenih časovnih vrst vektorjev diagnostičnih značilnosti in morfoloških značilnosti LPT segmenta ST **Z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI**, za posnetek s20421 podatkovne baze LTST DB od časa 04:00 [hh:mm] do časa 07:00. Vidni so neishemični paralelni pomiki segmenta ST in prehodne ishemične epizode segmenta ST. *Od zgoraj navzdol:* srčna frekvenca  $h(j)$  v [utr/min]; v časovnem prostoru izmerjeni nivo segmenta ST  $s_1(2, j)$  in v časovnem prostoru izmerjeni nagib segmenta ST  $s_5(2, j)$  (navpična os:  $100\mu V/\text{razdelek}$ ); eksperimentalno označene prehodne epizode segmenta ST (ozki pravokotniki); vizualizirane časovne vrste prvih petih koeficientov LPT segmenta ST  $s_{L,k}(2, j)$  s pripadajočo Mahalanobisovo razdaljo  $d_{L,k}(2, j)$  (navpična os:  $1\sigma/\text{razdelek}$ ). *Spodaj:* Slike srčnih utripov ob oznakah A, B in C v časovnih vrstah; pred paralelnim pomikom [04:13:26.176], po paralelnem pomiku [04:43:30.416] in v ekstremni ishemični epizodi segmenta ST [06:30:08.056]. Na srčnih utripih so označeni segment ST ("ST<sub>D</sub>"), izoelektrični nivo ("ISO"), koleno J in točka merjenja nivoja segmenta ST v časovnem prostoru ("F+120 ms").

## Slika 7.9


*Spodaj:* vizualizacija primera 30-minutnega poteka časovnih vrst morfoloških značilk KLT segmenta ST **Z DINAMIČNIM PRILAGANJEM SRČNI FREKVENCI**, ekspertnih oznak prehodnih epizod segmenta ST (v sredini) in 30-minutnega poteka časovnih vrst morfoloških značilk LPT segmenta ST **Z DINAMIČNIM PRILAGANJEM SRČNI FREKVENCI**, v okolici prehodne ishemične epizode segmenta ST, ki kaže ukrivljenost segmenta ST (prvi odvod posnetka s30681 LTST DB, od časa 10:06 [hh:min] do časa 10:36). *Zgoraj:* Prikaz EKG srčnega utripa z ishemijo (polna črta), ki se kaže z ukrivljanjem segmenta ST, zajetega na mestu oznake "X" v časovnih vrstah, v primerjavi z normalnim neishemičnim referenčnim srčnim utripom (črtkana črta), zajetega na mestu oznake "R" v časovnih vrstah.



gorija morfoloških sprememb v posamičnem srčnem utripu je tako lahko posebno z uporabno časovnih vrst LPT prepoznana že zgolj z vizualno analizo prikaza časovnih vrst za daljše obdobje. S slike 7.9 tako lahko ob poteku prehodne ishemične epizode razberemo depresijo segmenta ST (prvi koeficient LPT), ki je ob ekstremu epizode (po pričakovanjih v skladu z definicijo ekstrema epizode) največja, prehodni padec in nato naraščanje pozitivnega nagiba segmenta ST ob razvoju epizode (drugi koeficient LPT) ter prav tako naraščanje ukrivljenosti segmenta ST skozi prehodno ishemično epizodo.

Na sliki 7.10 je prikazan EKG srčnega utripa ob ekstremu v LTST DB označene epizode neishemičnega odstopanja morfologije segmenta ST. Razvidno je, da spremembo morfologije na tradicionalnem področju opazovanja segmenta ST povzroča val T, ki se je zaradi povišane srčne frekvence pomaknil v to področje. Sama morfologija segmenta ST pa ne odstopa znatno, če jo opazujemo le pred valom T. Ker gre za razmeroma izrazit primer z zelo približanim in hkrati povišanim valom T, ta pojav vendarle vnaša v celotni segment ST nekaj pozitivnega nagiba. Od novih prilagodljivih časovnih vrst

Slika 7.10



Spodaj: vizualizacija primera 30-minutnega poteka časovnih vrst morfoloških značilnik KLT segmenta ST z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI, ekspertnih oznak prehodnih epizod segmenta ST (v sredini) in 30-minutnega poteka časovnih vrst morfoloških značilnik LPT segmenta ST z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI, v okolici prehodne neishemične epizode segmenta ST, ki je posledica pomika vala T proti kompleksu QRS (prvi odvod posnetka s20431 LTST DB, od časa 00:30 [hh:min] do časa 01:00). Zgoraj: Prikaz EKG srčnega utripa z neishemično spremembo segmenta ST (polna črta), ki je posledica pomika vala T proti kompleksu QRS, zajetega na mestu oznake "X" v časovnih vrstah, v primerjavi z normalnim referenčnim srčnim utripom (črtkana črta), zajetega na mestu oznake "R" v časovnih vrstah.

tako pričakujemo, da ne bodo pokazale znatnega "lažnega" povišanja nivoja segmenta ST, kar se v praksi prav tako izkaže na vizualiziranih podatkih prvega koeficienta tako LPT kot tudi KLT. Po pričakovanjih z drugim koeficientom zaznamo zmeren pozitivni nagib, ukrivljenost (tretji koeficient) pa ni izrazita. V nadaljevanju učinkovitost prilagajanja algoritmov v odvisnosti od srčne frekvence razčlenimo še natančneje.

Takšni rezultati so konsistentni z oblikami baznih funkcij LPT (konstantna funkcija, linearna funkcija, kvadratna funkcija). Spremembe v morfologiji so enako izrazito opazne tudi v koeficientih transformacije KLT, vendar so vrednosti koeficientov KLT manj jasne in enostavno razumljive. Bazne funkcije KLT namreč nimajo povsem jasnih elementarnih oblik kot LPT. Kljub vsemu so rezultati obeh transformacij primerljivi in tudi razmeroma podobni. To je pričakovano, saj so bazne funkcije KLT podobne baznim funkcijam LPT. Tudi pri KLT so denimo prve tri funkcije podobne konstanti, linearni funkciji in kvadratni funkciji, vendar so razlike že v obrnjenem predznaku in

so tudi v splošnem po obliki kompleksnejše.

Od algoritmov za zajem morfoloških značilk, ki smo jih nadgradili z dinamičnim prilagajanjem dolžine okna za zajem vzorcev (srčni frekvenci), pričakujemo natančnejše zajemanje resničnih morfoloških lastnosti preiskovanega intervala in občutljivost za morfološke lastnosti, ki v preiskovani interval ne sodijo. Zato na naslednjih primerih časovne vrste vektorjev morfoloških značilk segmenta ST, ki smo jih pridobili s predhodnimi algoritmi brez dinamičnega prilagajanja srčni frekvenci, primerjamo s časovnimi vrstami, ki smo jih pridobili z algoritmi z dinamičnim prilagajanjem širine okna za zajem vzorcev srčni frekvenci. Na slikah 7.11, 7.12, 7.13 in 7.14 lahko med seboj primerjamo vizualizacije pridobljenih časovnih vrst vektorjev diagnostičnih parametrov in morfoloških značilk LPT in KLT segmenta ST, tako brez dinamičnega prilagajanja srčni frekvenci kot z dinamičnim prilagajanjem srčni frekvenci za isti izsek posnetka s3o661 (prvi odvod) podatkovne baze LTST DB od časa 05:15 [hh:mm] do časa 06:45. Posnetek vsebuje izrazite spremembe srčne frekvence, kar povzroča spremembe dolžine srčnega utripa v signalu EKG in posledično tudi spremembe dolžine segmenta ST.


Na slikah 7.11 in 7.12 so vizualizirani trendi časovnih vrst (v trajanju 1 h in 30 min) diagnostičnih parametrov, izmerjenih v časovnem prostoru (zgoraj), in trendi časovnih vrst vektorjev morfoloških značilk LPT brez prilagajanja srčni frekvenci (slika 7.11, v sredini) in trendi časovnih vrst vektorjev morfoloških značilk LPT s prilagodljivo širino okna zajema časovnih vzorcev srčni frekvenci (slika 7.12, v sredini). Že iz pregleda celotnega poteka je v časovnih vrstah brez prilagajanja srčni frekvenci (slika 7.11), posebno v intervalu povišane srčne frekvence ob označeni epizodi odstopanja segmenta ST med 5:47 in 6:35, opaziti izrazitejša nihanja. Prilagodljive časovne vrste (slika 7.12) v tem pogledu kažejo večjo stabilnost. Iz ekspertno določenih kliničnih podatkov vemo, da gre na intervalu označene epizode (spremenjene morfologije) segmenta ST za razmeroma enotno morfologijo, ki do ekstreme epizode (na sliki označena točka "C") postaja vse izrazitejša (to je razvidno tudi iz točkovno merjenega poteka nivoja segmenta ST, "ST level [ $\mu V$ ]"). Nihanja koeficientov neprilagodljivih morfoloških časovnih vrst tako nakazujejo, da so te tudi občutljivejše na prisotnost procesov, kot so alternance vala T [69], ki v morfoloških časovnih vrstah za segment ST pomenijo motnjo. Podobne razlike v stabilnosti signala opazamo tudi ob pregledu celotnega poteka časovnih vrst vektorjev morfoloških značilk KLT brez dinamičnega prilagajanja (slika 7.13) in časovnih vrst KLT z dinamičnim prilagajanjem (slika 7.14) širine okna za zajem vzorcev

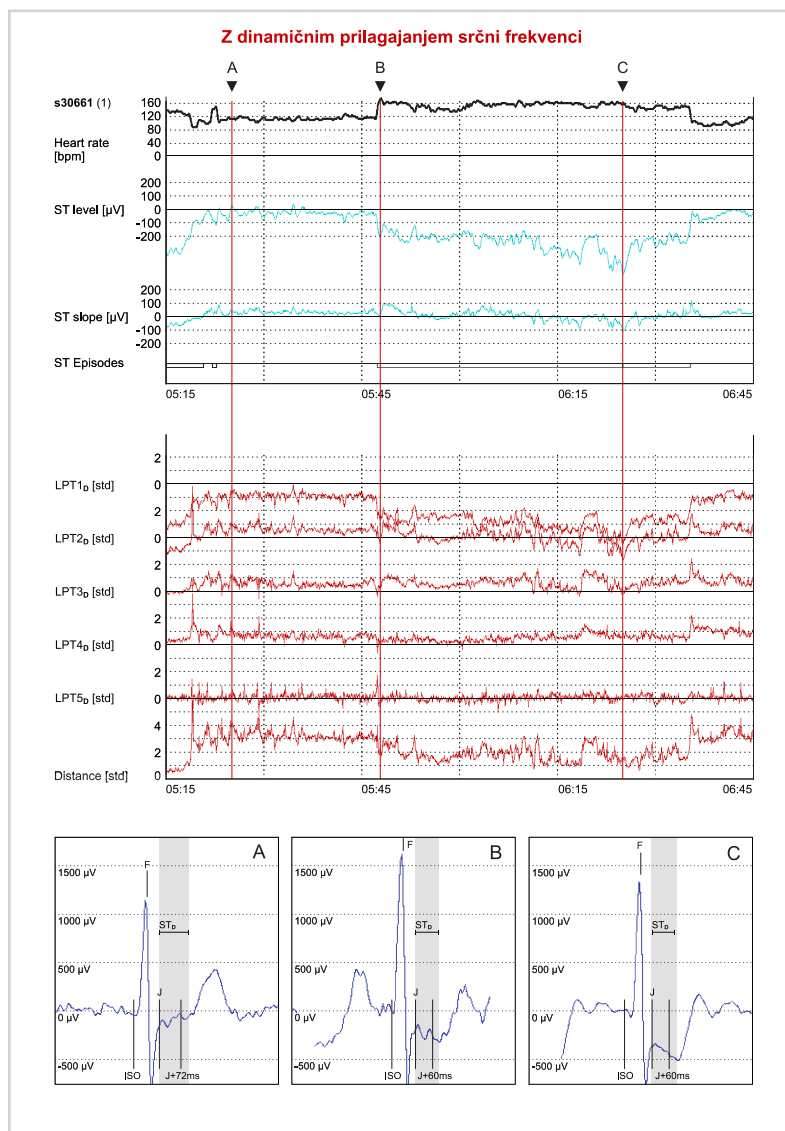
srčni frekvenci.

S slike EKG segmenta ST srčnega utripa "A" (levo-spodaj na slikah 7.11, 7.12, 7.13, 7.14) je razvidna rahla depresija nivoja segmenta ST (posiveno področje na sliki EKG srčnega utripa), ki se odraža v negativni vrednosti časovne vrste prvega koeficienta srčni frekvenci prilagodljive LPT, " $LPT1_D$ ", pri označbi "A". Funkcija nivoja segmenta ST, "ST level [ $\mu V$ ]", ki jo sestavljajo meritve v označeni točki ("J + 72 ms" pri utripu "A") v časovnem prostoru, na tem mestu (označba "A" v časovnih vrstah) kaže pozitivno vrednost (tj. rahlo elevacijo nivoja segmenta ST). Točkovna meritev je manj odporna na lokalna nihanja v segmentu ST (drobnejše morfološke posebnosti in višje-frekvenčne motnje), saj zajema zgolj lastnost glede na eno postavljeno točko, medtem ko je za klinično diagnostiko pomemben potek segmenta ST v celoti. Na sliki EKG srčnega utripa "A" je dobro opazno lokalno "valovanje" v segmentu ST, ki znatno vpliva na točkovno meritev nivoja segmenta ST v označeni točki "J+72 ms". Časovne vrste KLT in LPT brez dinamičnega prilagajanja srčni frekvenci (sliki 7.11 in 7.13) depresije prav tako ne zaznajo. Njihova ocena nivoja segmenta ST je namreč natančna – napačno povišana. Na sliki srčnega utripa "A" vidimo, da zaradi ožanja segmenta ST kot posledice nekoliko povišane srčne frekvence (pri srčnem utripu "A" znaša 109 utripov v minuti) s konstantno širino okna za zajem vzorcev segmenta ST (na slikah srčnih utripov označeno z "ST") neprilagodljivi algoritmi zajamejo tudi del vala T. Ta ima tipično bistveno višji nivo od segmenta ST. Zato je ocena nivoja segmenta ST s prvim koeficientom transformacije LPT, " $LPT1$ ", (in KLT, " $KLT1$ ", če poskušamo tudi s pomočjo slednje ocenjevati nivo – upoštevajoč negativen predznak in tudi manj čisto obliko bazne funkcije) brez prilagajanja srčni frekvenci manj natančna ob spreminjanju se srčni frekvenci. Ta pojav postane še izrazitejši v nadaljnjem poteku ekspertno označene epizode depresije segmenta ST med 5:47 in 6:35, ko se srčna frekvenca še poviša. Prvi koeficient neprilagodljive transformacije LPT, " $LPT1$ ", na več mestih zaznava celo elevacijo nivoja segmenta ST. Čeprav tako ocena nivoja segmenta ST s točkovno meritvijo v časovnem prostoru ("ST level [ $\mu V$ ]") kot prvi koeficient prilagodljive transformacije LPT, " $LPT1_D$ ", (in KLT, " $KLT1_D$ ") kažeta izrazito depresijo preko celotne epizode, skladno tudi z ekspertno oznako. Prvi koeficient neprilagodljive transformacije KLT, " $KLT1$ ", je nekoliko natančnejši in ne kaže elevacije, vendar je ocena depresije tekom označene epizode depresije tudi s slednjim znatno manj izrazita. Pravilno oceno morfologije dajo v primeru srčnega utripa "A" tako zgolj transformacije z dinamičnim prilagajanjem srčni frekvenci.

### Slika 7.11

Vizualizacija trendov pridobljenih časovnih vrst vektorjev diagnostičnih parametrov in morfoloških značilnik LPT segmenta ST BREZ DINAMIČNEGA PRILAGAJANJA SRČNI FREKVENCI za posnetek s30661 (prvi odvod) podatkovne baze LTST DB od časa 05:15 [hh:mm] do časa 06:45. Posnetek vsebuje izrazite spremembe srčne frekvence, kar povzroča spremembe dolžine srčnega utripa v signalu EKG in posledično tudi spremembe dolžine segmenta ST. Od zgoraj navzdol: srčna frekvenca  $h(j)$  v [ut/min]; v časovnem prostoru izmerjeni nivo segmenta ST  $s_1(2, j)$  in v časovnem prostoru izmerjeni nagib segmenta ST  $s_5(2, j)$  (navpična os:  $100\mu\text{V}/\text{razdelek}$ ); eksperto označene prehodne epizode segmenta ST (ozki pravokotniki); vizualizirane časovne vrste petih koeficientov LPT segmenta ST  $s_{K, k}(2, j)$  s pripadajočo Mahalanobisovo razdaljo  $d_{K, k}(2, j)$  (navpična os:  $1\sigma/\text{razdelek}$ ). Spodaj: Slike EKG srčnih utripov ob oznakah A, B in C v časovnih vrstah. Na srčnih utripih so označeni izoelektrični nivo ("ISO"), koleno J in točka merjenja nivoja segmenta ST v časovnem prostoru ("J + X ms"; vrednost X v skladu s podatki v tabeli 3.2) ter interval zajema vzorčnega vektorja segmenta ST s statično dolžino 120 ms, "ST".






Slika 7.12


Vizualizacija trendov pridobljenih časovnih vrst vektorjev diagnostičnih parametrov in morfoloških značilnik LPT segmenta ST **Z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI** za posnetek s30661 (prvi odvod) podatkovne baze LTST DB od časa 05:15 [hh:mm] do časa 06:45. Posnetek vsebuje izrazite spremembe srčne frekvence, kar povzroča spremembe dolžine srčnega utripa v signalu EKG in posledično tudi spremembe dolžine segmenta ST. Od zgoraj navzdol: srčna frekvenca  $h(j)$  v [utr/min]; v časovnem prostoru izmerjeni nivo segmenta ST  $s_1(2, j)$  in v časovnem prostoru izmerjeni nagib segmenta ST  $s_2(2, j)$  (navpična os:  $100 \mu V / \text{razdelek}$ ); eksperto označene prehodne epizode segmenta ST (ozki pravokotniki); vizualizirane časovne vrste prvih petih koeficientov LPT segmenta ST  $s_{K, k}(2, j)$  s pripadajočo Mahalanobisovo razdaljo  $d_{K(2, j)}$  (navpična os:  $1 \sigma / \text{razdelek}$ ). Spodaj: Slike EKG srčnih utripov ob oznakah A, B in C v časovnih vrstah. Na srčnih utripih so označeni izoelektrični nivo ("ISO"), koleno J in točka merjenja nivoja segmenta ST v časovnem prostoru ("J + X ms"; vrednost X v skladu s podatki v tabeli 3.2) ter interval zajema vzorčnega vektorja segmenta ST s srčni frekvenci prilagodljivo dolžino, "ST<sub>D</sub>" (dolžina v skladu s podatki v tabeli 3.3).

## Slika 7.13

Vizualizacija trendov pridobljenih časovnih vrst vektorjev diagnostičnih parametrov in morfoloških značilk KLT segmenta ST BREZ DINAMIČNEGA PRILAGAJANJA SRČNI FREKVENCI za posnetek s30661 (prvi odvod) podatkovne baze LTST DB od časa 05:15 [hh:mm] do časa 06:45. Posnetek vsebuje izrazite spremembe srčne frekvence, kar povzroča spremembe dolžine srčnega utripa v signalu EKG in posledično tudi spremembe dolžine segmenta ST. Od zgoraj navzdol: srčna frekvenca  $h(j)$  v [ut/min]; v časovnem prostoru izmerjeni nivo segmenta ST  $s_1(2, j)$  in v časovnem prostoru izmerjeni nagib segmenta ST  $s_2(2, j)$  (navpična os: 100  $\mu\text{V}/\text{razdelek}$ ); eksperto označene prehodne epizode segmenta ST (ozki pravokotniki); vizualizirane časovne vrste prvih petih koeficientov KLT segmenta ST  $s_{K, k}(2, j)$  s pripadajočo Mahalanobisovo razdaljo  $d_{K, k}(2, j)$  (navpična os: 1  $\sigma/\text{razdelek}$ ). Spodaj: Slike EKG srčnih utripov ob oznakah A, B in C v časovnih vrstah. Na srčnih utripih so označeni izoelektrični nivo ("ISO"), koleno J in točka merjenja nivoja segmenta ST v časovnem prostoru ("J + X ms"; vrednost X v skladu s podatki v tabeli 3.2) ter interval zajema vzorčnega vektorja segmenta ST s statično dolžino 120 ms, "ST".








Slika 7.14

Vizualizacija trendov pridobljenih časovnih vrst vektorjev diagnostičnih parametrov in morfoloških značilnik KLT segmenta ST **Z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI** za posnetek s30661 (prvi odvod) podatkovne baze LTST DB od časa 05:15 [hh:mm] do časa 06:45. Posnetek vsebuje izrazite spremembe srčne frekvence, kar povzroča spremembe dolžine srčnega utripa v signalu EKG in posledično tudi spremembe dolžine segmenta ST. Od zgoraj navzdol: srčna frekvenca  $h(j)$  v [utr/min]; v časovnem prostoru izmerjeni nivo segmenta  $ST_{s_1}(2, j)$  in v časovnem prostoru izmerjeni nagib segmenta  $ST_{s_2}(2, j)$  (navpična os:  $100 \mu V / \text{razdelek}$ ); eksperto označene prehodne epizode segmenta ST (ozki pravokotniki); vizualizirane časovne vrste prvih petih koeficientov KLT segmenta  $ST_{s_K}, k(2, j)$  s pripadajočo Mahalanobisovo razdaljo  $d_K(2, j)$  (navpična os:  $1 \sigma / \text{razdelek}$ ). Spodaj: Slike EKG srčnih utripov ob oznakah A, B in C v časovnih vrstah. Na srčnih utripih so označeni izoelektrični nivo ("ISO"), koleno J in točka merjenja nivoja segmenta ST v časovnem prostoru ("J" + X ms); vrednost X v skladu s podatki v tabeli 3.2) ter interval zajema vzorčnega vektorja segmenta ST s srčni frekvenci prilagodljivo dolžino, "ST<sub>D</sub>" (dolžina v skladu s podatki v tabeli 3.3).

Na sliki signala EKG segmenta ST pri srčnem utripu "B" (spodaj na slikah 7.11, 7.12, 7.13, 7.14) je v segmentu ST (posiveno področje v srčnem utripu na slikah) opazen rahel nagib navzdol (tj. negativen nagib). Funkcija nagiba segmenta ST, "ST slope [ $\mu V$ ]", ki jo sestavljajo v časovnem prostoru merjene razlike med na sliki srčnega utripa označeno točko meritve nivoja segmenta ST ("J + 60 ms" pri utripu "B") in točko J + 20 ms, na mestu tega srčnega utripa v časovnih vrstah ("B") kaže pozitivno vrednost (tj. rahel nagib navzgor v segmentu ST). To je posledica manjše odpornosti točkovne meritve na lokalne morfološke posebnosti oziroma (višje frekvenčne) motnje. Na sliki EKG srčnega utripa "B" je dobro opazno lokalno "valovanje" v segmentu ST, ki znatno vpliva na točkovne meritve v časovnem prostoru. Ocena nagiba segmenta ST z drugim koeficientom prilagodljive transformacije LPT, " $LPT_2D$ ", je natančnejša in daje pravilno negativno vrednost. Časovne vrste LPT in KLT brez dinamičnega prilagajanja srčni frekvenci (sliki 7.11 in 7.13) prav tako ne zaznajo negativnega nagiba. Pri srčnih utripih "B" in "C", pri katerih je srčna frekvenca razmeroma močno povišana (176 utripov v minuti pri srčnem utripu "B" in 150 utripov v minuti pri srčnem utripu "C") je namreč napaka pri oceni morfologije z neprilagodljivimi algoritmi znatna. Na slikah EKG srčnih utripov "B" in "C" vidimo veliko razliko v označeni širini okna za zajem vzorcev segmenta ST neprilagodljivih algoritmov (" $ST$ ") v primerjavi s prilagodljivimi algoritmi (" $ST_D$ "), kjer je širina okna določena po razviti funkciji v tabeli 3.3. Pri teh srčnih utripih neprilagodljivi algoritem zajame tudi velik del vala T, kar vodi v povsem napačne ocene morfologije. Predvsem pa so te ocene morfologije nato nekompatibilne (neprimerljive) z ocenami morfologije pri drugačnih srčnih frekvencah. To je opazno še zlasti pri srčnem utripu "C" ob ekstremu označene epizode segmenta ST, kjer morfologija vala T predstavlja kar okvirno tretjino neprilagodljivo zajetega signala. Slika EKG segmenta ST srčnega utripa "C" kaže zelo izrazit nagib navzdol, medtem ko drugi koeficient neprilagodljive transformacije, " $LPT_2$ ", s katerim bi želeli oceniti morfološko lastnost nagiba, kaže celo nagib navzgor (pozitivna vrednost). To je posledica prisotnosti vala T v zajetem vzorčnem intervalu. Ta ima namreč še izrazitejši nagib navzgor, kar izniči meritev nagiba pravega segmenta ST, hkrati pa je za klinično diagnostiko nepomemben. Drugi koeficient transformacije LPT z dinamičnim prilagajanjem dolžine zajema vzorcev segmenta ST srčni frekvenci, " $LPT_2D$ ", daje ob srčnem utripu "C" glede na sliko srčnega utripa pričakovano močno negativno meritev, ki se sklada tudi z vrednostjo nagiba, izmerjeno v časovnem prostoru.

Na sliki 7.15 primerjamo trende diagnostične časovne vrste nivoja segmenta ST, "ST




Slika 7.15

Primerjava trendov diagnostične časovne vrste nivoja segmenta ST, "ST level [ $\mu V$ ]", in morfoloških časovnih vrst prvega koeficienta LPT in KLT segmenta ST brez dinamičnega prilagajanja srčni frekvenci ("LPT1" in "KLT1") in časovnih vrst prvega koeficienta LPT in KLT z dinamičnim prilagajanjem srčni frekvenci ("LPT1<sub>D</sub>" in "KLT1<sub>D</sub>") za posnetek s30661 (prvi odvod) podatkovne baze LTST DB od časa 05:15 [hh:mm] do časa 06:45.

level [ $\mu V$ ]", ki je bil merjen s točkovnimi meritvami v časovnem prostoru in morfoloških časovnih vrst prvega koeficienta LPT in KLT segmenta ST brez dinamičnega prilagajanja srčni frekvenci ("LPT1" in "KLT1") in časovnih vrst prvega koeficienta LPT in KLT z dinamičnim prilagajanjem srčni frekvenci ("LPT1<sub>D</sub>" in "KLT1<sub>D</sub>"). Prikazan je primer iz posnetka s30661 (prvi odvod) podatkovne baze LTST DB od časa 05:15 [hh:mm] do časa 06:45. Vidimo lahko, da prvi koeficient transformacije LPT z dinamičnim prilagajanjem ("LPT1<sub>D</sub>", obarvan rdeče) na sliki 7.15 dobro sledi v časovnem prostoru merjenemu nivoju segmenta ST, medtem ko rezultati neprilagodljivih algoritmov obeh transformacij znatno odstopajo in so prav tako tudi manj izraziti. Prvi koeficient transformacije KLT z dinamičnim prilagajanjem ("KLT1<sub>D</sub>", obarvan rdeče) sicer prav tako izkazuje občutljivost ob morfoloških spremembah, ki jih kaže diagnostična časovna vrsta nivoja segmenta ST, vendar so njeni rezultati znatno odstopajoči že zaradi nasprotnega predznaka.

Slika 7.16

Primerjava trendov diagnostične časovne vrste nagiba segmenta ST, "ST slope [ $\mu\text{V}$ ]", in morfoloških časovnih vrst drugega koeficienta LPT in KLT segmenta ST BREZ DINAMIČNEGA PRILAGAJANJA SRČNI FREKVENCI ("LPT2" in "KLT2") in časovnih vrst drugega koeficienta LPT in KLT z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI ("LPT2<sub>D</sub>" in "KLT2<sub>D</sub>") za posnetek s30661 (prvi odvod) podatkovne baze LTST DB od časa 05:15 [hh:mm] do časa 06:45.



Podobne rezultate lahko opazujemo tudi na sliki 7.16, kjer primerjamo časovno vrsto drugega koeficienta transformacij s prilagodljivo širino okna zajema vzorčnih vektorjev segmenta ST srčni frekvenci ("LPT2<sub>D</sub>" in "KLT2<sub>D</sub>") s časovno vrsto drugega koeficienta neprilagodljivih transformacij ("LPT2" in "KLT2") in diagnostično časovno vrsto nagiba segmenta ST, "ST slope [ $\mu\text{V}$ ]", kot je bil izmerjen s točkovnimi meritvami v časovnem prostoru na istem primeru kot pri sliki 7.15. Drugi koeficient transformacije LPT z dinamičnim prilagajanjem ("LPT2<sub>D</sub>", obarvan rdeče) na sliki 7.16 tako rekoč povsem sledi v časovnem prostoru merjenemu nivoju segmenta ST, medtem ko rezultati neprilagodljivih algoritmov znatno odstopajo in mestoma dajejo celo zavajajoče meritve. Tudi pri drugem koeficient transformacije KLT z dinamičnim prilagajanjem ("KLT2<sub>D</sub>", obarvan rdeče) opazimo občutljivost ob morfoloških spremembah, ki jih kaže diagnostična časovna vrsta nagiba segmenta ST, vendar so prav tako njeni rezultati znatno odstopajoči že zaradi nasprotnega predznaka.

Rezultati algoritmov za zajem morfoloških značilk, ki smo jih nadgradili z dinamičnim prilagajanjem srčni frekvenci, nam tako kažejo znatno večjo natančnost opisovanja morfologije segmenta ST ob spreminjajoči se srčni frekvenci v primerjavi s tradicionalnimi metodami s fiksnim zajemom vzorcev segmenta ST. Hkrati je takšno opisovanje morfologije tudi odpornejše na drobne morfološke posebnosti in motnje v segmentu ST v primerjavi s tradicionalnimi metodami v časovnem prostoru.

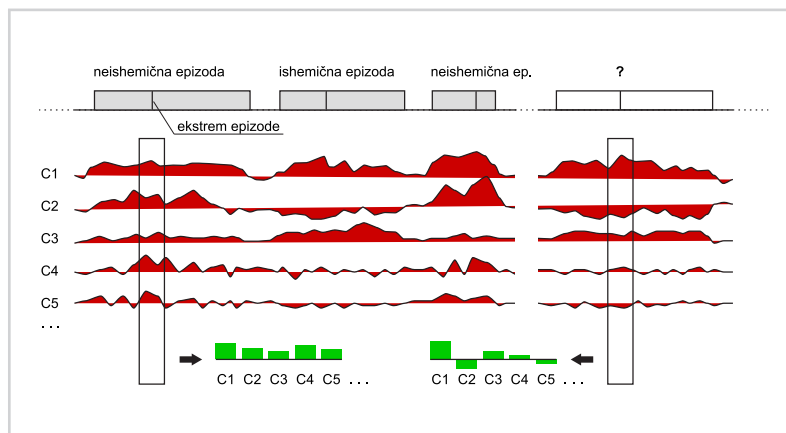
### *7.3 Klasifikacija med prehodnimi ishemičnimi in neishemičnimi epizodami segmenta ST*

Poleg ekspertne človeške diagnostike preko vizualiziranih trendov so pomembno področje uporabe novih metod za ocenjevanje morfologije in izločanje morfoloških značilk tudi prihodnji zmogljivejši sistemi za avtomatsko detekcijo klinično pomembnih dogodkov, ki se odražajo v segmentu ST elektrokardiograma. Zato želimo na študiji primera klasifikacije med prehodnimi ishemičnimi in neishemičnimi epizodami, ki so ekspertno označene v podatkovni bazi LTST DB, oceniti klasifikacijsko zmogljivost značilk, pridobljenih s prilagodljivima transformacijama KLT in LPT. Primarni namen te študije ni bil razvoj detekcijskega sistema, temveč na čim bolj elementarnem preglednem primeru primerjati nove metode z dinamičnim prilagajanjem srčni frekvenci s starejšimi metodami brez prilagajanja in prav tako primerjati novo transformacijo LPT s tradicionalnejšo KLT. Detekcijski sistemi na drugi strani danes namreč za značilke uporabljajo poleg morfoloških vektorjev značilk ortogonalnih transformacij še različne druge parametre, na primer tudi srčno frekvenco, hkrati pa tudi različne tehnike dodatnega predprocesiranja značilk (npr. izračun razlik vzorčnih vektorjev pred nastopom epizode, po nastopu epizode in v ekstremu epizode) in različne metode za izbor značilk [35–37]. V teh delih so bile tako uporabljene značilke, zajete iz diagnostičnih in morfoloških časovnih vrst, kakršni so nivo segmenta ST, razmerje med nizkimi in visokimi frekvenčnimi komponentami (LF/HF) srčne frekvence, koren srednje kvadratne spremembe (RMS) oblike segmenta ST in tudi značilke, pridobljene kot razlike med različnimi točkami v poteku epizode (pred začetkom, po začetku, v ekstremu) na osnovi srčne frekvence, nagiba segmenta ST, pozitivnega nagiba vala R, korena srednje kvadratne spremembe (RMS) oblike kompleksa QRS in Mahalanobisove razdalje koeficientov KLT kompleksov QRS in segmentov ST. Vendar pa bi takšni pristopi v naši študiji po drugi strani zmanjšali jasnost slike, ki jo želimo pridobiti o zmogljivosti samih transformacij KLT in LPT za izločanje morfoloških značilk in primerjavo

s starejšimi neprilagodljivimi metodami. Zato v tej študiji uporabljamo zgolj vektorje morfoloških značilk KLT in LPT. Hkrati je delovanje klasifikacije zgolj z uporabo enostavnih značilk, kot so koeficienti transformacij KLT in LPT segmenta ST, lahko tudi pomembna prednost. Pri naši metodi je namreč potrebno le določanje stabilne referenčne točke, kar je že rešeno z uveljavljenimi algoritmi [54]. Tako se izognemo različnim zaporednim procesom priprave podatkov in predobdelav, kjer je večja možnost kopičenja napake. Na primer določanje položaja kolena J, ki je zahteven in manj zanesljiv proces, v našem pristopu ni potrebno. Rezultate tega primera klasifikacije zato ne gre primerjati s trenutno najboljšimi rezultati drugih skupin v svetu, četudi v nadaljevanju (poglavje 8) predstavimo tudi primerjavo s slednjimi, saj so pridobljeni rezultati z morfološkimi značilkami prilagodljivih KLT in LPT zelo obetajoči za prihodnji razvoj učinkovitejših detektorjev.

Klasificirali smo epizode spremenjene morfologije segmenta ST (slika 7.17) celotne podatkovne baze LTST DB v razred epizod, ki jih povzroča ishemijska, in v razred neishemijskih epizod, ki so posledica povišane srčne frekvence [68]. Ta razreda epizod sta prav tako ekspertno označena v podatkovni bazi LTST DB v obliki oznak časovnih intervalov prisotnosti posamičnih epizod in oznak razreda, ki mu posamične epizode pripadajo (slika 7.17). Uporabili smo nabor uveljavljenih klasifikatorjev, ki so že implementirani v okolju MathWorks MATLAB Statistics and Machine Learning Toolbox: Klasifikacijsko drevo (angl. Classification Tree) (CT), K najbližjih sosedov (angl. K Nearest Neighbors) s  $k = 3$  (3NN) sosedi, Linearno diskriminantno analizo (angl. Linear Discriminant Analysis) (LDA), Naivni Bayesov klasifikator (angl. Naive Bayes Classifier) (NBC), Kvadratno diskriminantno analizo (angl. Quadratic Discriminant Analysis) (QDA) in Metodo podpornih vektorjev (angl. Support Vector Machines) z linearnim (SVML) in kvadratnim (SVMQ) jedrom.

Vsako epizodo, označeno v podatkovni bazi LTST DB glede na protokol B [10] za označevanje epizod, v vsakem odvodu EKG, smo predstavili s srednjim vektorjem morfoloških značilk KLT in LPT, izračunanim v 20-sekundni okolici ekstreme epizode. Na sliki 7.18 je na primeru epizode prvega odvoda posnetka LTST DB s20011 z ekstremom v označeni točki "E" prikazan izračun srednjih vektorjev značilk KLT in LPT za to epizodo (magnitudo komponent pridobljenega vektorja so označene z zeleno barvo). Za vsako tako v LTST DB označeno epizodo odstopanja segmenta ST zajamemo podmnožico vseh vektorjev iz časovnih vrst vektorjev morfoloških značilk KLT (primer vidimo na sliki 7.18, kjer je prikazan časovni potek prvih petih vektor-




Slika 7.17

Prikaz postopka klasifikacije med ishemičnimi in neishemičnimi epizodami podatkovne baze LTST DB na osnovi vektorjev morfoloških značilk (na sliki je ilustriran časovni potek prvih petih komponent vektorjev, tj. koeficientov transformacij KLT ali LPT, "C1" do "C5") v okolici ekstremov posamičnih epizod.

skih komponent "KLT 1" do "KLT 5", v rdeči barvi, zgoraj) in LPT (primer vidimo na sliki 7.18, kjer je prikazan časovni potek prvih petih vektorskih komponent "LPT 1" do "LPT 5", v rdeči barvi, spodaj), ki jih vsebuje 20-sekundna okolica ekstreme epizode (med točkama "E-10s" in "E+10s" na sliki). Nato izračunamo srednje vrednosti posamičnih komponent v obeh tako zajetih množicah vektorjev morfoloških značilk KLT in LPT. Izračunane srednje vrednosti (na sliki prikazane z zeleno barvo) tvorijo komponente pridobljenih srednjih vektorjev značilk KLT in LPT, s kakršnima bo v procesu klasifikacije predstavljena vsaka epizoda.

Z uporabo značilk zgolj v ekstremih epizod brez uporabe značilk v različnih točkah poteka epizode se izognemo tudi določanju začetkov in koncev epizod, ki je prav tako zahtevno in manj stabilno. Postopek določanja ekstreme epizode je trivialen. S to metodo smo zgradili množico 1130 primerov vektorjev morfoloških značilk 1130 ishemičnih epizod segmenta ST in 234 primerov vektorjev morfoloških značilk 234 neishemičnih epizod segmenta ST. Na takšen način pridobljene vektorje morfoloških značilk vsake posamične epizode smo nato uporabili v testiranju zmogljivosti klasifikacije izbranih klasifikatorjev z desetkratnim prečnim preverjanjem.

V osnovnem primeru smo klasifikatorje testirali s tremi vnaprej izbranimi podmnožicami koeficientov (tj. komponent vektorjev morfoloških značilk), oblikovanih v skladu z vrstnim redom izračunanih standardnih deviacij koeficientov nad podatkovno bazo LTST DB (poglavje 6.4) za vsako od transformacij KLT in LPT posebej: koeficienti



Slika 7.18

Prikaz metode pridobitve srednjih vektorjev morfoloških značilik KLT in LPT na primeru za epizodo iz prvega odvoda posnetka LTST DB s20011 z eks-tremom ob času 20:24:08 (točka "E").

1–3, koeficienti 1–5 in koeficienti 1–8. Ker smo želeli oceniti, ali bi širjenje nabora koeficientov lahko nadalje izboljšalo rezultate, smo v študijo dodali še nabor koeficientov 1–9. Izmerjene zmogljivosti klasifikatorjev smo opredelili z naslednjimi merami zmogljivosti:

klasifikacijska točnost  $CA$ ,

$$CA = \frac{TP + TN}{TP + FN + TN + FP} \quad , \quad (7.1)$$



občutljivost  $Se$ ,

$$Se = \frac{TP}{TP + FN} , \quad (7.2)$$

in specifičnost  $Sp$ ,

$$Sp = \frac{TN}{TN + FP} , \quad (7.3)$$

kjer  $TP$  pomeni število pravilno klasificiranih primerov pozitivnega razreda (ishemične epizode klasificirane kot ishemične),  $FN$  pomeni število napačno klasificiranih primerov pozitivnega razreda (ishemične epizode klasificirane kot neishemične),  $TN$  pomeni število pravilno klasificiranih primerov negativnega razreda (neishemične epizode klasificirane kot neishemične) in  $FP$  pomeni število napačno klasificiranih primerov negativnega razreda (neishemične epizode klasificirane kot ishemične).

V tabeli 7.1 so prikazani rezultati testiranja izbranih klasifikatorjev z značilkami (koeficienti), pridobljenimi z algoritmi KLT in LPT brez dinamičnega prilagajanja srčni frekvenci. Najvišjo klasifikacijsko točnost doseže klasifikator K najbližjih sosedov ( $k = 3$ ), na osnovi transformacije KLT s koeficienti 1–8:  $Se = 91\%$ ,  $Sp = 85\%$  in  $CA = 90\%$  in na osnovi transformacije LPT s koeficienti 1–9:  $Se = 86\%$ ,  $Sp = 74\%$  in  $CA = 84\%$ . V tabeli 7.2 pa so prikazani rezultati testiranja izbranih klasifikatorjev z značilkami (koeficienti), pridobljenimi z algoritmi KLT in LPT z dinamičnim prilagajanjem srčni frekvenci. Najvišjo klasifikacijsko točnost z novimi prilagodljivimi algoritmi doseže klasifikator K najbližjih sosedov ( $k = 3$ ) s koeficienti 1–8. Koeficienti obeh transformacij dosežejo zelo primerljive rezultate, KLT:  $Se = 89\%$ ,  $Sp = 82\%$  in  $CA = 88\%$  ter LPT:  $Se = 89\%$ ,  $Sp = 83\%$  in  $CA = 88\%$ .

Slika 7.19 prikazuje rezultate klasifikacijske točnosti ( $CA$ ) klasifikacije z značilkami na osnovi transformacij KLT in LPT brez dinamičnega prilagajanja srčni frekvenci in z značilkami na osnovi transformacij KLT in LPT z dinamičnim prilagajanjem srčni frekvenci. Opazimo, da so rezultati klasifikacije s srčni frekvenci prilagodljivimi značilkami LPT (tabela 7.2, največja  $CA = 88\%$ , klasifikator 3NN, v tabeli označeno rdeče) bistveno boljši od rezultatov z neprilagodljivimi značilkami LPT (tabela 7.1, največja  $CA = 82\%$ , klasifikator 3NN, v tabeli označeno rdeče). Pri uporabi neprilagodljivih algoritmov je klasifikacijska točnost značilk LPT slabša od značilk KLT (tabela 7.1, največja  $CA = 90\%$ , klasifikator 3NN, v tabeli označeno rdeče), medtem ko se

Tabela 7.1

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT BREZ DINAMIČNEGA PRILAGAJANJA SRČNI FREKVENCI s klasifikatorji Klasifikacijsko drevo (CT), K najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosedih, Linearna diskriminantna analiza (LDA), Naivni Bayesov klasifikator (NBC), Kvadratna diskriminantna analiza (QDA), Metoda podpornih vektorjev z linearnim (SVM) in kvadratnim (SVMQ) jedrom ( $Se$  - Občutljivost,  $Sp$  - Specifičnost,  $CA$  - Klasifikacijska točnost). Rezultati klasifikatorja z najvišjo točnostjo so obarvani.


(brez dinamičnega prilagajanja)		KLT			LPT		
		$Se$	$Sp$	$CA$	$Se$	$Sp$	$CA$
Coeff. 1-3	3NN	0.79	0.74	0.78	0.69	0.61	0.68
	4NN	0.76	0.83	0.77	0.64	0.65	0.64
	5NN	0.72	0.86	0.74	0.59	0.73	0.62
	CT	0.82	0.56	0.78	0.78	0.47	0.73
	LDA	0.67	0.59	0.66	0.61	0.50	0.59
	NBC	0.71	0.68	0.70	0.62	0.67	0.63
	QDA	0.53	0.85	0.58	0.47	0.85	0.53
	SVM	0.66	0.62	0.65	0.61	0.51	0.59
	SVMQ	0.72	0.64	0.71	0.59	0.63	0.60
Coeff. 1-5	3NN	0.88	0.82	0.87	0.83	0.75	0.82
	4NN	0.85	0.84	0.85	0.79	0.82	0.79
	5NN	0.82	0.86	0.83	0.75	0.84	0.76
	CT	0.87	0.63	0.83	0.84	0.59	0.80
	LDA	0.74	0.71	0.73	0.62	0.74	0.64
	NBC	0.81	0.69	0.79	0.70	0.70	0.70
	QDA	0.69	0.82	0.71	0.61	0.82	0.65
	SVM	0.72	0.72	0.72	0.62	0.71	0.63
	SVMQ	0.79	0.75	0.78	0.77	0.74	0.76
Coeff. 1-8	3NN	0.91	0.85	0.90	0.85	0.72	0.82
	4NN	0.89	0.85	0.88	0.82	0.79	0.81
	5NN	0.87	0.87	0.87	0.79	0.80	0.79
	CT	0.90	0.68	0.86	0.86	0.56	0.81
	LDA	0.73	0.74	0.74	0.63	0.71	0.65
	NBC	0.83	0.73	0.81	0.74	0.67	0.73
	QDA	0.90	0.53	0.84	0.90	0.40	0.81
	SVM	0.71	0.72	0.71	0.63	0.70	0.64
	SVMQ	0.81	0.76	0.81	0.81	0.74	0.79
Coeff. 1-9	3NN	0.91	0.80	0.89	0.86	0.74	0.84
	4NN	0.89	0.83	0.88	0.82	0.78	0.81
	5NN	0.87	0.85	0.87	0.78	0.79	0.78
	CT	0.88	0.58	0.83	0.85	0.52	0.80
	LDA	0.75	0.72	0.74	0.65	0.66	0.65
	NBC	0.84	0.71	0.82	0.78	0.67	0.76
	QDA	0.92	0.43	0.84	0.89	0.35	0.79
	SVM	0.71	0.73	0.71	0.63	0.71	0.65
	SVMQ	0.81	0.75	0.80	0.83	0.72	0.81

Tabela 7.2

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI s klasifikatorji Klasifikacijsko drevo (CT), K najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosedi, Linearna diskriminantna analiza (LDA), Naivni Bayesov klasifikator (NBC), Kvadratna diskriminantna analiza (QDA), Metoda podpornih vektorjev z linearnim (SVML) in kvadratnim (SVMQ) jedrom (*Se* - Občutljivost, *Sp* - Specifičnost, *CA* - Klasifikacijska točnost). Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(z dinamičnim prilagajanjem)		KLT			LPT		
		<i>Se</i>	<i>Sp</i>	<i>CA</i>	<i>Se</i>	<i>Sp</i>	<i>CA</i>
Coeff. 1-3	3NN	0.76	0.78	0.76	0.76	0.75	0.76
	4NN	0.72	0.85	0.74	0.70	0.80	0.72
	5NN	0.68	0.85	0.71	0.66	0.83	0.69
	CT	0.83	0.59	0.79	0.83	0.63	0.80
	LDA	0.69	0.59	0.67	0.69	0.59	0.67
	NBC	0.74	0.66	0.72	0.72	0.66	0.71
	QDA	0.58	0.85	0.62	0.54	0.85	0.60
	SVML	0.66	0.60	0.65	0.67	0.60	0.65
	SVMQ	0.57	0.47	0.55	0.71	0.65	0.70
Coeff. 1-5	3NN	0.86	0.85	0.86	0.85	0.84	0.85
	4NN	0.82	0.89	0.83	0.82	0.84	0.82
	5NN	0.79	0.89	0.81	0.79	0.87	0.80
	CT	0.87	0.64	0.83	0.88	0.60	0.83
	LDA	0.75	0.69	0.74	0.75	0.72	0.74
	NBC	0.79	0.73	0.78	0.76	0.69	0.75
	QDA	0.79	0.75	0.78	0.87	0.63	0.83
	SVML	0.73	0.70	0.73	0.74	0.70	0.73
	SVMQ	0.62	0.50	0.60	0.77	0.74	0.76
Coeff. 1-8	3NN	0.89	0.82	0.88	0.89	0.83	0.88
	4NN	0.86	0.87	0.86	0.86	0.86	0.86
	5NN	0.84	0.86	0.84	0.84	0.86	0.84
	CT	0.87	0.59	0.82	0.87	0.60	0.83
	LDA	0.75	0.71	0.74	0.75	0.71	0.74
	NBC	0.81	0.75	0.80	0.80	0.66	0.77
	QDA	0.92	0.38	0.82	0.92	0.34	0.82
	SVML	0.75	0.70	0.74	0.74	0.70	0.73
	SVMQ	0.57	0.50	0.56	0.79	0.77	0.79
Coeff. 1-9	3NN	0.89	0.82	0.88	0.88	0.84	0.87
	4NN	0.86	0.85	0.86	0.87	0.84	0.87
	5NN	0.85	0.89	0.85	0.84	0.86	0.84
	CT	0.87	0.61	0.83	0.86	0.62	0.82
	LDA	0.75	0.69	0.74	0.75	0.70	0.74
	NBC	0.81	0.74	0.80	0.81	0.68	0.79
	QDA	0.91	0.37	0.82	0.92	0.35	0.83
	SVML	0.75	0.68	0.74	0.74	0.71	0.74
	SVMQ	0.59	0.47	0.57	0.81	0.79	0.81

Slika 7.19



Vizualizacija rezultatov klasifikacijske točnosti (CA, navpična os) klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT, levo: brez dinamičnega prilagajanja srčni frekvenci ("1-X KLT" in "1-X LPT", X pomeni število uporabljenih koeficientov), desno: z dinamičnim prilagajanjem srčni frekvenci ("1-X KLT" in "1-X LPT", X pomeni število uporabljenih koeficientov). Izbrani klasifikatorji so bili Klasifikacijsko drevo (CT), K najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosedi, Linearna diskriminantna analiza (LDA), Naivni Bayesov klasifikator (NBC), Kvadratna diskriminantna analiza (QDA), Metoda podpornih vektorjev z linearnimi (SVML) in kvadratnimi (SVMQ) jedrom na časovnih vrstah vektorjev morfoloških značilk KLT in LPT. Za primerjavo so s črno črtkano črto dodatno izrisane tudi izmerjene klasifikacijske točnosti klasifikatorja K najbližjih sosedov pri  $k = 3$  (3NN) sosedih z uporabo značilk, pridobljenih na osnovi za faktor  $R=1.5$  razširjenega zajema segmenta ST z dinamičnim prilagajanjem srčni frekvenci, ki daje najboljše rezultate klasifikacije (predstavljeno v nadaljevanju).

klasifikacijska točnost značilk obeh transformacij (KLT in LPT), pridobljenih s prilagodljivimi algoritmi, povsem izenači.

Da bi si še s primerom klasifikacije potrdili ustreznost izbire dimenzije transformiranega prostora (9 koeficientov transformacij KLT in LPT po padajočem vrstnem redu njihovih standardnih deviacij), smo za v prejšnjih testih najtočnejši klasifikator K najbližjih sosedov ( $k = 3$ ) testirali njegovo točnost pri vseh podmnožicah koeficientov 1-3, 1-4, 1-5, ..., 1-9 (tabela 7.3). Izkaže se, da klasifikacijska točnost razmeroma hitro narašča do podmnožice koeficientov 1-6 pri koeficientih KLT in do podmnožice koeficientov 1-7 pri koeficientih LPT, nato pa se rast točnosti ustali in začne pri podmnožici koeficientov 1-9 (LPT) padati. Izbrana zmanjšana dimenzija transformiranega prostora oziroma število izdelanih časovnih vrst vektorjev morfoloških značilk – tj. prvih devet koeficientov – je tako ustrezna tudi za potrebe računalniške klasifikacije. Četudi se klasifikacijska točnost v tabeli 7.3 ustali že med 1-7 in 1-8, je namreč pomembno, da imamo na razpolago še nekoliko širši razpon, da lahko takšen trend

Tabela 7.3

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI s klasifikatorjem K najbližjih sosedov s  $k = 3$  (3NN) sosedih z značilkami izbranih podmnožic koeficientov 1-3, 1-4, 1-5, ..., 1-9. Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(z dinamičnim prilagajanjem)			KLT			LPT		
			Se	Sp	CA	Se	Sp	CA
Coeff. 1-3	3NN		0.76	0.78	0.76	0.76	0.75	0.76
Coeff. 1-4	3NN		0.81	0.83	0.81	0.83	0.82	0.83
Coeff. 1-5	3NN		0.86	0.85	0.86	0.85	0.84	0.85
Coeff. 1-6	3NN		0.88	0.84	0.88	0.86	0.81	0.85
Coeff. 1-7	3NN		0.89	0.84	0.88	0.87	0.83	0.86
Coeff. 1-8	3NN		0.89	0.82	0.88	0.89	0.83	0.88
Coeff. 1-9	3NN		0.89	0.82	0.88	0.88	0.84	0.87

zaznamo. Hkrati nam to dopušča tudi možnosti nadaljnega ocenjevanja morebitne uporabnosti širših naborov koeficientov v drugih primerih uporabe ali ob drugačnih pogojih.

Ob primerjavi rezultatov v tabelah 7.1 in 7.2 prav tako opazimo, da so klasifikacijske točnosti klasifikacije z značilkami prilagodljive KLT za majhen delež nižje od neprilagodljive KLT. Največja klasifikacijska točnost (klasifikator 3NN) slednjih je  $CA = 88\%$ , medtem ko je največja klasifikacijska točnost (klasifikator 3NN) na osnovi neprilagodljivih algoritmov  $CA = 90\%$ . Prilagodljive algoritme KLT in LPT smo namreč razvili s ciljem čim bolj natančnega zajemanja morfologije izključno segmenta ST. Iz sorodnih študij ([35–37]) pa vemo, da so za klasifikacijo med ishemičnimi in neishemičnimi epizodami poleg segmenta ST koristni tudi drugi intervali EKG, kot sta kompleks QRS in val T. Naše neprilagodljive časovne vrste denimo pogosto zajemajo tudi ravno del morfologije vala T. Slednje lahko bolj izkoristi (neprilagodljiva) transformacija KLT, ki temu prilagodi tudi bazne funkcije. Pomembna usmeritev našega nadaljnega dela je zato ravno razvoj klasifikacijskega sistema, ki bo poleg prilagodljivih časovnih vrst KLT in/ali LPT za optimalno natančno ocenjevanje morfologije segmenta ST uporabljal tudi izbor nekaterih drugih značilk, pridobljenih iz srčne frekvence, vala T in kompleksa QRS.


Takšno usmeritev nam potrjuje tudi študija naslednjega primera, ko za preizkus uporabimo značilke, pridobljene s prilagodljivimi algoritmi, ki smo jih izračunali na osnovi za določen linearni faktor povečanih vrednosti razvite funkcije dolžine segmenta ST v odvisnosti od srčne frekvence (tabela 3.3). S tem smo okno zajema vzorčnih vektorjev

Tabela 7.4

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT z **DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI**, katerih funkcijo dolžine segmenta ST v odvisnosti od srčne frekvence spremenimo za faktor  $R$ , s klasifikatorjem K najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosedih z značilkami koeficientov 1–9. V prvi vrsti so za primerjavo dodani tudi rezultati klasifikacije **BREZ DINAMIČNEGA PRILAGAJANJA SRČNI FREKVENCI** s klasifikatorjem K najbližjih sosedov s  $k = 3$  (3NN\*),  $k = 4$  (4NN\*) in  $k = 5$  (5NN\*) sosedih z značilkami koeficientov 1–9. Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(z dinamičnim prilagajanjem, * brez dinamičnega prilagajanja)			KLT			LPT		
	$R$		$Se$	$Sp$	$CA$	$Se$	$Sp$	$CA$
Coeff. 1–9	3NN*	1	0.91	0.80	0.89	0.86	0.74	0.84
	3NN	0.9	0.79	0.67	0.77	0.88	0.77	0.86
	3NN	1	0.89	0.82	0.88	0.88	0.84	0.87
	3NN	1.25	0.89	0.77	0.87	0.90	0.86	0.89
	3NN	1.5	0.92	0.85	0.91	0.91	0.86	0.90
	3NN	1.75	0.91	0.87	0.90	0.75	0.69	0.74
Coeff. 1–9	4NN*	1	0.89	0.83	0.88	0.82	0.78	0.81
	4NN	0.9	0.85	0.79	0.84	0.86	0.79	0.85
	4NN	1	0.86	0.85	0.86	0.87	0.84	0.87
	4NN	1.25	0.87	0.82	0.86	0.87	0.87	0.87
	4NN	1.5	0.89	0.88	0.89	0.88	0.87	0.88
	4NN	1.75	0.88	0.89	0.88	0.87	0.86	0.87
Coeff. 1–9	5NN*	1	0.87	0.85	0.87	0.78	0.79	0.78
	5NN	0.9	0.83	0.85	0.83	0.83	0.82	0.83
	5NN	1	0.85	0.89	0.85	0.84	0.86	0.84
	5NN	1.25	0.85	0.83	0.84	0.85	0.89	0.85
	5NN	1.5	0.87	0.90	0.88	0.86	0.90	0.87
	5NN	1.75	0.85	0.91	0.86	0.84	0.86	0.84

podaljšali, da zajame še val T. Za klasifikacijo sedaj uporabimo skupno morfologijo intervala ST-T. Tako pridobljene značilke nam dajo najvišjo točnost klasifikacije. So namreč še vedno prilagodljive in zato kljub zajemanju vhodnih vzorcev istih razredov ob različnih srčnih frekvencah zagotavljajo njihovo kompatibilnost (primerljivost). Slednje je bistveno za učinkovito klasifikacijo. Ti rezultati so prikazani v tabeli 7.4, klasifikacijska točnost pa je vizualizirana tudi na na sliki 7.20. Za ta namen smo pripravili nove dodatne časovne vrste vektorjev morfoloških značilk KLT in LPT (in tudi baze funkcije KLT) z 0.9, 1.25, 1.5 in 1.75-kratnikom dolžine segmenta ST, določene po funkciji v tabeli 3.3. S tako pridobljenimi novimi časovnimi vrstami vektorjev morfoloških značilk smo ponovno izvedli postopek testiranja najučinkovitejšega klasifikatorja K najbližjih sosedov ( $k = 3$ ) za izbor koeficientov 1–9. Klasifikacijska točnost znatno narašča do 1.5-kratnika naše osnovne formule, za tem pa zopet pade. Nato smo pri



Slika 7.20

Vizualizacija rezultatov klasifikacijske točnosti ( $CA$ , navpična os) iz tabele 7.4. Klasificirali smo med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENC, katerih funkcijo dolžine segmenta ST v odvisnosti od srčne frekvence spremenimo za faktor  $R$  (vodoravna os), s klasifikatorjem  $K$  najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosedi z značilkami koeficientov 1–9. Za primerjavo je kot začetna vrednost dodana tudi klasifikacijska točnost z značilkami BREZ DINAMIČNEGA PRILAGAJANJA SRČNI FREKVENC pri  $R = 1$  (označeno z \*).

1.5-kratniku ( $R = 1.5$ ) dolžine segmenta ST izvedli še testiranje vseh izbranih klasifikatorjev. Rezultate prikazuje tabela 7.5.

V tabeli 7.6 so za primerjavo prikazani tudi rezultati testiranja izbranih klasifikatorjev z značilkami KLT na osnovi predhodnih baznih funkcij, pridobljenih na osnovi podatkovne baze ESC DB (slika 4.3), prav tako brez dinamičnega prilagajanja srčni frekvenci, ki jih uporabljajo dosedanje sorodne študije [35–37]. Največja klasifikacijska točnost (klasifikator CT) z značilkami teh starejših baznih funkcij je še nekoliko nižja ( $CA = 70\%$ ). Sklepamo, da gre to pripisati dejstvu, da so bile te bazne funkcije izdelane na podatkovni bazi ESC DB, ki je okvirno desetkrat manjša in vsebuje manj reprezentativen nabor različnih morfologij, med drugim sploh ne vsebuje neishemičnih epizod. Hkrati je dolžina (tj. ločljivost) vhodnih vektorjev polovico manjša (16 vzorcev, na enakem zajetem časovnem intervalu segmenta ST F+40 ms do F+160 ms).

Nadalje smo želeli opredeliti, ali nadgradnja matematičnega modela za določanje širine okna za zajem segmenta ST glede na srčno frekvenco (3.34), ki smo ga izpeljali

iz Bazettove formule, s preslikavo, ki smo jo lahko izpeljali za nekatere intervale srčne frekvence na osnovi ekspertno določenih podatkov za položaj točke merjenja nivoja segmenta ST v podatkovni bazi LTST DB (tabela 3.2), izboljša natančnost značilk. Zato smo pripravili posebno različico časovnih vrst vektorjev morfoloških značilk KLT in LPT z dinamičnim prilagajanjem srčni frekvenci z uporabo zgolj matematičnega modela na osnovi Bazettove formule (3.34) brez upoštevanja preslikave za določitev širine okna za zajem segmenta ST na osnovi ekspertnih podatkov (glej sliko 3.2). Izmerjena zmogljivost klasifikacije s tako pridobljenimi časovnimi vrstami (tabela 7.7) je primerljiva z rezultati časovnih vrst, dobljenih s prilagodljivimi algoritmi (tabela 7.2), a v skladu s pričakovanji nekoliko nižja (okvirno 1% do 2% *CA*).



Tabela 7.5

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilniki na osnovi transformacij KLT in LPT **Z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI**, katerih funkcijo dolžine segmenta ST v odvisnosti od srčne frekvence spremenimo za faktor  $R = 1.5$ , s klasifikatorji Klasifikacijsko drevo (CT), K najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosed, Linearna diskriminantna analiza (LDA), Naivni Bayesov klasifikator (NBC), Kvadratna diskriminantna analiza (QDA), Metoda podpornih vektorjev z linearnim (SVML) in kvadratnim (SVMQ) jedrom ( $Se$  - Občutljivost,  $Sp$  - Specifičnost,  $CA$  - Klasifikacijska točnost). Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(z dinamičnim prilagajanjem, $R = 1.5$ )		KLT			LPT		
		$Se$	$Sp$	$CA$	$Se$	$Sp$	$CA$
Coeff. 1-3	3NN	0.75	0.72	0.75	0.76	0.72	0.75
	4NN	0.71	0.75	0.71	0.70	0.77	0.71
	5NN	0.68	0.80	0.70	0.65	0.79	0.68
	CT	0.83	0.58	0.79	0.82	0.54	0.77
	LDA	0.69	0.63	0.68	0.70	0.69	0.70
	NBC	0.70	0.74	0.70	0.75	0.64	0.73
	QDA	0.55	0.85	0.60	0.55	0.85	0.60
	SVML	0.69	0.67	0.68	0.69	0.72	0.70
	SVMQ	0.55	0.48	0.54	0.72	0.74	0.73
Coeff. 1-5	3NN	0.89	0.89	0.89	0.88	0.86	0.88
	4NN	0.87	0.91	0.88	0.85	0.88	0.86
	5NN	0.85	0.93	0.86	0.83	0.91	0.84
	CT	0.90	0.68	0.87	0.89	0.65	0.85
	LDA	0.74	0.77	0.75	0.74	0.77	0.74
	NBC	0.80	0.79	0.80	0.75	0.77	0.76
	QDA	0.68	0.87	0.71	0.69	0.88	0.72
	SVML	0.74	0.79	0.75	0.74	0.79	0.75
	SVMQ	0.56	0.48	0.54	0.78	0.77	0.78
Coeff. 1-8	3NN	0.91	0.84	0.90	0.90	0.85	0.89
	4NN	0.90	0.90	0.90	0.88	0.90	0.88
	5NN	0.87	0.91	0.87	0.85	0.88	0.85
	CT	0.89	0.71	0.86	0.89	0.67	0.85
	LDA	0.76	0.77	0.76	0.75	0.79	0.76
	NBC	0.83	0.82	0.83	0.77	0.75	0.77
	QDA	0.91	0.59	0.85	0.90	0.58	0.85
	SVML	0.75	0.79	0.75	0.74	0.80	0.75
	SVMQ	0.59	0.47	0.57	0.81	0.79	0.80
Coeff. 1-9	3NN	0.92	0.85	0.91	0.91	0.86	0.90
	4NN	0.89	0.88	0.89	0.88	0.87	0.88
	5NN	0.87	0.90	0.88	0.86	0.90	0.87
	CT	0.90	0.67	0.86	0.88	0.68	0.85
	LDA	0.76	0.77	0.76	0.75	0.79	0.76
	NBC	0.84	0.80	0.83	0.80	0.75	0.79
	QDA	0.91	0.49	0.84	0.92	0.52	0.85
	SVML	0.74	0.79	0.75	0.74	0.79	0.75
	SVMQ	0.59	0.51	0.58	0.80	0.79	0.80

Tabela 7.6

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacije KLT s predhodnimi baznimi funkcijami, pridobljenimi na podatkovni bazi ESC DB, ki so jih uporabljali starejši algoritmi, BREZ DINAMIČNEGA PRILAGAJANJA SRČNI FREKVENCI, s klasifikatorji Klasifikacijsko drevo (CT), K najbližjih sosedov s  $k = 3$  (3NN) sosedi, Linearna diskriminantna analiza (LDA), Naivni Bayesov klasifikator (NBC), Kvadratna diskriminantna analiza (QDA), Metoda podpornih vektorjev z linearnim (SVML) in kvadratnim (SVMQ) jedrom na časovnih vrstah vektorjev morfoloških značilk KLT ( $Se$  - Občutljivost,  $Sp$  - Specifičnost,  $CA$  - Klasifikacijska točnost). Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(brez dinamičnega prilagajanja)		KLT		
		$Se$	$Sp$	$CA$
Coeff. 1-3	3NN	0.63	0.68	0.64
	CT	0.74	0.38	0.67
	LDA	0.34	0.65	0.40
	NBC	0.52	0.79	0.58
	QDA	0.31	0.86	0.42
	SVML	0.34	0.64	0.40
	SVMQ	0.55	0.51	0.54
Coeff. 1-5	3NN	0.66	0.68	0.67
	CT	0.75	0.39	0.68
	LDA	0.60	0.82	0.65
	NBC	0.49	0.78	0.55
	QDA	0.55	0.86	0.61
	SVML	0.60	0.81	0.64
	SVMQ	0.54	0.46	0.52
Coeff. 1-8	3NN	0.66	0.72	0.67
	CT	0.75	0.48	0.70
	LDA	0.59	0.80	0.63
	NBC	0.48	0.82	0.54
	QDA	0.59	0.85	0.64
	SVML	0.59	0.83	0.64
	SVMQ	0.49	0.40	0.48
Coeff. 1-9	3NN	0.66	0.75	0.68
	CT	0.78	0.53	0.73
	LDA	0.61	0.78	0.64
	NBC	0.47	0.80	0.54
	QDA	0.59	0.87	0.64
	SVML	0.59	0.77	0.62
	SVMQ	0.60	0.42	0.56

Tabela 7.7

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI z uporabo zgolj matematičnega modela, ki smo ga izpeljali na osnovi Bazettove formule (3.34), s klasifikatorji Klasifikacijsko drevo (CT), K najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosedih, Linearna diskriminantna analiza (LDA), Naivni Bayesov klasifikator (NBC), Kvadratna diskriminantna analiza (QDA), Metoda podpornih vektorjev z linearnim (SVML) in kvadratnim (SVMQ) jedrom ( $Se$  - Občutljivost,  $Sp$  - Specifičnost,  $CA$  - Klasifikacijska točnost). Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(z dinamičnim prilagajanjem)		KLT			LPT		
		$Se$	$Sp$	$CA$	$Se$	$Sp$	$CA$
Coeff. 1-3	3NN	0.80	0.77	0.79	0.79	0.76	0.78
	4NN	0.75	0.85	0.76	0.74	0.82	0.75
	5NN	0.71	0.85	0.73	0.69	0.83	0.72
	CT	0.84	0.59	0.80	0.86	0.58	0.82
	LDA	0.70	0.65	0.70	0.70	0.64	0.69
	NBC	0.73	0.69	0.72	0.73	0.70	0.73
	QDA	0.61	0.83	0.65	0.59	0.83	0.63
	SVML	0.70	0.64	0.69	0.68	0.63	0.67
	SVMQ	0.63	0.44	0.60	0.66	0.50	0.63
Coeff. 1-5	3NN	0.85	0.82	0.85	0.85	0.80	0.84
	4NN	0.82	0.85	0.82	0.81	0.85	0.82
	5NN	0.79	0.89	0.81	0.79	0.86	0.80
	CT	0.86	0.59	0.81	0.85	0.65	0.82
	LDA	0.74	0.69	0.73	0.75	0.72	0.74
	NBC	0.79	0.73	0.78	0.75	0.68	0.74
	QDA	0.84	0.65	0.81	0.86	0.59	0.81
	SVML	0.72	0.69	0.71	0.74	0.72	0.74
	SVMQ	0.60	0.53	0.58	0.59	0.45	0.57
Coeff. 1-8	3NN	0.88	0.79	0.86	0.89	0.79	0.87
	4NN	0.85	0.82	0.84	0.86	0.82	0.85
	5NN	0.83	0.85	0.83	0.83	0.86	0.83
	CT	0.86	0.62	0.82	0.87	0.56	0.82
	LDA	0.75	0.71	0.74	0.75	0.72	0.75
	NBC	0.81	0.74	0.79	0.79	0.66	0.77
	QDA	0.90	0.39	0.81	0.93	0.32	0.82
	SVML	0.75	0.71	0.74	0.74	0.72	0.74
	SVMQ	0.64	0.55	0.63	0.55	0.50	0.54
Coeff. 1-9	3NN	0.88	0.76	0.86	0.89	0.79	0.87
	4NN	0.86	0.82	0.85	0.86	0.82	0.86
	5NN	0.83	0.82	0.83	0.83	0.85	0.83
	CT	0.85	0.57	0.80	0.88	0.59	0.83
	LDA	0.76	0.67	0.74	0.75	0.69	0.74
	NBC	0.81	0.70	0.79	0.80	0.69	0.78
	QDA	0.92	0.35	0.82	0.92	0.33	0.82
	SVM	0.76	0.69	0.75	0.74	0.70	0.73
	SVMQ	0.63	0.50	0.60	0.55	0.56	0.55



# *Razprava*

8

### *8.1 Algoritem za dinamično prilagajanje dolžine vhodnih vzorčnih vektorjev segmenta ST spreminjajoči se srčni frekvenci*

Dosedanje metode za ocenjevanje morfologije segmenta ST elektrokardiograma niso upoštevale učinka ožanja in širjenja segmenta ST na časovni osi kot posledice spreminjajoče se srčne frekvence. Zato so prav tako viri na področju metod za določanje dolžine segmenta ST v odvisnosti od srčne frekvence omejeni. V ta namen smo razvili nov algoritem, ki temelji na dveh pristopih na povezanih področjih (slika 3.2, tabela 3.3): določanje korigirane diagnostične dolžine intervala QT z Bazettovo formulo [8] in določanje položaja točke merjenja nivoja segmenta ST glede na srčno frekvenco, kot so ga postavili eksperti kardiologi ob razvoju podatkovne baze LTST DB [10]. Opravljena študija določanja dolžine segmenta ST na osnovi srčne frekvence z razvito funkcijo pokaže, da je takšno sledenje spreminjajoči se časovni dolžini segmenta ST ob spreminjajoči se srčni frekvenci izvedljivo, da razvita funkcija spremembam v dolžini segmenta ST dobro sledi (slike 7.1 - 7.6) in da bo algoritem možno uporabiti za nadaljnji razvoj srčni frekvenci prilagodljivih sistemov.

Nove transformacije KLT in LPT z dinamičnim prilagajanjem srčni frekvenci omogočajo celovitejši in natančnejši zajem morfoloških značilk za avtomatsko analizo v primerjavi s tradicionalnimi metodami zajemanja diagnostičnih parametrov v časovnem prostoru na osnovi ene same točke merjenja. Za metode ocenjevanja morfoloških lastnosti z ortogonalno transformacijo določanje položaja kolena J prav tako ni potrebno.

Nova transformacija LPT s prilagodljivo širino okna za zajem vzorčnih vektorjev nudi ekspertom kardiologom možnost za točen in hiter pregled razvoja prehodnih patoloških ali nepatoloških pojavov pri pacientih ter tako tudi hitrejšo in učinkovitejšo ekspertno diagnostiko. Hkrati je to tehniko mogoče standardizirati in uvesti v klinično prakso kot nov diagnostični kriterij.

### *8.2 Metoda za ocenjevanje značilnih sprememb morfologije segmenta ST na osnovi spreminjajoči se srčni frekvenci prilagodljivih transformacij KLT in LPT.*

V izvedenih evaluacijskih študijah (poglavje 7) so se Legendrovi polinomi kot baza nove prilagodljive ortogonalne transformacije segmenta ST elektrokardiograma, LPT, izkazali za učinkovite tako za ocenjevanje morfoloških značilk kot za vizualno predsta-

vitev diagnostično pomembnih sprememb oblik. Zaradi ortogonalnosti Legendrovih polinomov, enostavnega procesa generiranja baznih funkcij, boljše razumljivosti pomena časovnih vrst vektorjev značilik in primerljive zmogljivosti klasifikacije ishemičnih in neishemičnih sprememb tako pristop na osnovi Legendrovih polinomov predstavlja obetajočo alternativo tradicionalni transformaciji KLT na številnih področjih obdelave in diagnostike prehodnih ishemičnih in neishemičnih sprememb morfologije segmenta ST.

Vizualna analiza (poglavje 7.2) potrjuje, da nov pristop, temelječ na Legendrovih polinomih, omogoča natančno ocenjevanje in predstavitev morfologije segmenta ST, ki hkrati prinaša edinstveno možnost neposrednega vpogleda v klinično pomembne tipične spremembe morfologije segmenta ST v časovnem prostoru neposredno iz prostora transformacije LPT. V vizualizacijah trendov časovnih vrst morfoloških značilik LPT je jasno viden potek sprememb morfologije, kot so depresija ali elevacija, nagib navzgor ali navzdol ter ukrivljanje segmenta ST (sliki 7.8 in 7.7). Oblike prvih treh Legendrovih polinomov (konstanta, linearna in kvadratna funkcija) namreč natančno ustrezajo tem značilnostim in tako omogočajo optimalno ocenjevanje natančno treh v klinični praksi prepoznanih diagnostično pomembnih morfoloških lastnosti, kot so nivo, nagib in ukrivljenost [10]. Medtem ko diagnostični parametri, izmerjeni v časovnem prostoru s točkovnimi meritvami (v točkah J+80(60) ms in J+20 ms), omogočajo ocenjevanje nivoja segmenta ST in nagiba segmenta ST, transformacije LPT in KLT segmenta ST omogočajo ocenjevanje morfologije na osnovi informacije, ki je zajeta s celotnega segmenta ST (ne zgolj posamičnih točk) in zato omogočajo celovitejši ter prav tako točnejši vpogled v morfološke lastnosti segmenta ST. Hkrati takšen pristop k zajemanju morfologije omogoča natančno merjenje blagega ukrivljanja segmenta ST, ki je eden izmed ključnih kriterijev v klinični diagnostiki, a dosedanje metode niso omogočale avtomatskega ocenjevanja te lastnosti segmenta ST. Meritve ukrivljenosti v časovnem prostoru namreč niso dobro izvedljive. Tretji koeficient transformacije LPT (kvadratna funkcija) se konsistentno odziva z vizualno prepoznanimi oblikami segmenta ST s prisotnim blagim ukrivljanjem, kar lahko vidimo na sliki 7.9.

Kljub vsemu pa se do sedaj uporaba ortogonalnih transformacij v kardiološki diagnostiki ni močno uveljavila. Transformacija KLT namreč daje časovne vrste koeficientov, ki niso preprosto razločljive. Poleg tega smo z izvedeno študijo (poglavje 7.2) odvisnosti odzivanja ortogonalnih transformacij, kakršni sta KLT in LPT, na spreminjajočo se srčno frekvenco pokazali, da je učinek pogostega spreminjanja srčne frekvence doda-

ten in pomemben razlog za oteženo uporabnost rezultatov neprilagodljivih ortogonalnih transformacij. Slika vizualiziranih trendov takšne transformacije, ki ne upošteva spreminjajoče se srčne frekvence, je namreč lahko celo za enake razrede morfologij ob različnih srčnih frekvencah izrazito različna (sliki 7.11 in 7.12).

Koeficienti novih transformacij KLT in LPT, ki smo ju nadgradili z algoritmom za dinamično prilagajanje dolžine zajema vzorčnih vektorjev (sliki 7.15 in 7.16), tudi preko intervalov znatnih sprememb srčne frekvence konsistentno sledijo morfologiji, kljub spremenljivi dolžini segmenta ST, transformacija LPT pa še posebej dobro sledi morfološkim parametrom nivoja in nagiba. Oba postopka (KLT in LPT) sta tudi natančnejša od tradicionalnih avtomatskih metod v primerih motenj in drobnejših lokalnih morfologij. Poleg tega lahko ocenjujeta še druge diagnostično pomembne lastnosti, kot je ukrivljenost, česar tradicionalne avtomatske metode ne omogočajo.

Pomemben razlog, da do sedaj ni prišlo do širše uveljavitve uporabe transformacije KLT v klinični diagnostiki, je najverjetneje tudi njena osnovna lastnost, da je njena baza zgrajena na osnovi učne množice iz realnega sveta (poglavje 4.4). Zaradi različnih zastopanosti morfologij v različnih učnih množicah se bazne funkcije lahko med različnimi implementacijami precej razlikujejo, lahko denimo celo spremenijo predznak. Slednje pa bi lahko pomenilo povsem različne izhodne časovne vrste različnih analizatorjev, ki bi bili tako implementirani. Ker sodita standardizacija in zagotavljanje skladnosti rezultatov med ključna načela v razvoju medicinske diagnostične opreme, je to pomembna ovira, ki jo razvita transformacija LPT segmenta ST v celoti odpravlja.

### 8.3 *Metoda za klasifikacijo med prehodnimi ishemičnimi in neishemičnimi epizodami segmenta ST na osnovi srčni frekvenci prilagodljivega izločanja morfoloških značilk*

Kot pokaže študija primerov klasifikacije med prehodnimi ishemičnimi in neishemičnimi epizodami sprememb segmenta ST z značilkami KLT in LPT (poglavje 7.3), nadgradnja algoritmov z dinamičnim prilagajanjem spreminjajoči se srčni frekvenci bistveno izboljša rezultate zmogljivosti klasifikacije ob uporabi LPT. Neprilagodljive bazne funkcije KLT delno vsebujejo tudi različne morfologije ob različnih srčnih frekvencah (npr. prisotnost vala T v zajemu segmenta ST). Zato so morfološke značilke KLT pričakovano učinkovitejše pri ocenjevanju pomembnih morfologij, če segment ST ni natančno zajet, v primerjavi z morfološkimi značilkami transformacije LPT, katere baza je načrtno zasnovana za ocenjevanje pomembnih morfologij natančno zgolj segmen-



ta ST. To se odraža posebno na primerih klasifikacije z značilkami, pridobljenimi z neprilagodljivimi algoritmi (tabela 7.1), kjer dajejo značilke na osnovi (neprilagodljive) transformacije LPT razmeroma slabše rezultate od (neprilagodljive) transformacije KLT, medtem ko se rezultati klasifikacijske točnosti z značilkami transformacije LPT s prilagodljivimi algoritmi povsem izenačijo z meritvami točnosti klasifikacije na osnovi značilk prilagodljive transformacije KLT (tabela 7.2).

Sorodne študije v literaturi klasifikacijo med prehodnimi ishemičnimi in neishemičnimi epizodami izvajajo tako na osnovi različnih diagnostičnih parametrov, merjenih točkovno v časovnem prostoru, kot na osnovi ortogonalnih transformacij. Za optimizacijo rezultatov uporabljajo različne metode za izbiro in predprocesiranje značilk, kot denimo upoštevanje poteka epizode z vektorji razlike v posamičnih fazah prehodne epizode (pred začetkom, po začetku, v ekstremu) [35–37]. Takšen pristop z uporabo različnih predprocesiranih diagnostičnih in morfoloških parametrov ter s klasifikatorjem klasifikacijsko drevo, v podatkovni bazi LTST DB, nad učno množico, dosega občutljivost ( $Se$ ) 98% in specifičnost ( $Sp$ ) 86% [35]. Podoben pristop h klasifikaciji med prehodnimi ishemičnimi in neishemičnimi epizodami segmenta ST v podatkovni bazi LTST DB z uporabo različnih izborov predprocesiranih značilk na osnovi diagnostičnih in morfoloških parametrov, kot so srčna frekvenca ter koeficienti KLT segmenta ST in kompleksa QRS, z uporabo klasifikatorja na osnovi diskriminantne analize doseže z metodo "izpusti enega" (ang. "Leave one out") zmogljivosti klasifikacije epizod 85% ( $Se$ ) in 87% ( $Sp$ ) [36]. Pri naslednjem pristopu je bilo pred klasifikacijo ishemičnih in neishemičnih epizod segmenta ST podatkovne baze LTST DB izbranih devet vrst najučinkovitejših značilk iz začetnega nabora 35 vrst značilk z uporabo genetskega algoritma [37]. Uporabljene so bile značilke, zajete iz diagnostičnih in morfoloških časovnih vrst, kakršni so nivo segmenta ST, razmerje med nizkimi in visokimi frekvenčnimi komponentami (LF/HF) srčne frekvence, koren srednje kvadratne spremembe (RMS) oblike segmenta ST in tudi značilke, pridobljene kot razlike med različnimi točkami v poteku epizode (pred začetkom, po začetku, v ekstremu) na osnovi srčne frekvence, nagiba segmenta ST, pozitivnega nagiba vala R, korena srednje kvadratne spremembe (RMS) oblike kompleksa QRS in Mahalanobisove razdalje koeficientov KLT kompleksov QRS in segmentov ST. Z ishemičnimi in neishemičnimi epizodami podatkovne baze LTST DB so bile oblikovane učne in testne množice. Z uporabo nabora značilk srčne frekvence, nivoja segmenta ST, energije kompleksa QRS, Mahalanobisove razdalje prvih petih koeficientov KLT kompleksa QRS in segmenta ST za klasifikacijo

ishemičnih in neishemičnih epizod segmenta ST, označenih v podatkovni bazi LTST DB in z uporabo klasifikatorja Metode podpornih vektorjev je bila nad testno množico dosežena točnost klasifikacije  $CA = 87\%$  [37].

Naša študija namenoma uporablja izključno vektorje morfoloških značilke le transformacije KLT ali le transformacije LPT. Naš primarni namen v okviru tega dela namreč nista razvoj detekcijskega sistema in optimizacija točnosti slednjega, temveč na primeru ustrezno zahtevnega klasifikacijskega problema preveriti učinkovitost novih metod za pridobivanje morfoloških značilke za namene klasifikacije. Poleg tega smo želeli primerjati tudi novo transformacijo LPT s tradicionalnejšim pristopom, in sicer transformacijo KLT z vidikov klasifikacijske točnosti. S takšnim osnovnim pristopom z značilkami novih prilagodljivih algoritmov pri merjenju zmogljivosti klasifikacije med prehodnimi ishemičnimi in neishemičnimi epizodami, z desetkratnim prečnim preverjanjem nad podatkovno bazo LTST DB, z uporabo klasifikatorja K najbližjih sosedov s  $k = 3$  sosedov dobimo primerljive in boljše rezultate od zgoraj navedenih študij (KLT:  $Se = 89\%$ ,  $Sp = 82\%$  in  $CA = 88\%$  ter LPT:  $Se = 89\%$ ,  $Sp = 83\%$  in  $CA = 88\%$ , tabela 7.2, oziroma z razširjenim zajemom segmenta ST ( $R = 1.5$ ), KLT:  $Se = 92\%$ ,  $Sp = 85\%$  in  $CA = 91\%$  ter LPT:  $Se = 91\%$ ,  $Sp = 86\%$  in  $CA = 90\%$ , tabela 7.5). Morfološke značilke segmenta ST nove transformacije LPT z dinamičnim prilagajanjem srčni frekvenci dosegaajo v praksi enako zmogljivost kot značilke, pridobljene s prilagodljivo transformacijo KLT. Naš rezultat klasifikacije na osnovi KLT in LPT z razširjenim segmentom ST za faktor  $R = 1.5$  je v občutljivosti (KLT:  $Se = 92\%$ , LPT:  $Se = 91\%$ ) boljši od [36] ( $Se = 85\%$ ), v specifičnosti (KLT:  $Sp = 85\%$ , LPT:  $Sp = 86\%$ ) pa primerljiv s slednjim delom ( $Sp = 87\%$ ). Prav tako naša dosežena klasifikacijska točnost (KLT:  $CA = 91\%$ , LPT:  $CA = 90\%$ ) presega klasifikacijsko točnost, ki so jo poročali v delu [37] ( $CA = 87\%$ ). Klasifikacijske občutljivosti avtorjev [35] ( $Se = 98\%$ ,  $Sp = 86\%$ ) naši rezultati ne dosežejo, vendar pa je bila ta dobljena na učni množici.

V delih [35–37] so se osredotočili na optimizacijo rezultatov enega klasifikatorja. V okviru naše študije smo si zastavili nalogo izdelati pregled zmogljivosti različnih uveljavljenih klasifikatorjev za klasifikacijo prehodnih ishemičnih in neishemičnih epizod z morfološkimi značilkami KLT in LPT. Uporabljeni klasifikatorji so bili: Klasifikacijsko drevo, K najbližjih sosedov, Linearna diskriminantna analiza, Naivni Bayesov klasifikator, Kvadratna diskriminantna analiza in Metoda podpornih vektorjev z linearnim ter kvadratnim jedrom. Najboljše rezultate daje klasifikator K najbližjih sosedov s  $k = 3$

(3NN) sosedu. Prav tako so bile v primerjavi z našo študijo časovne vrste vektorjev morfoloških značilk KLT pri delih [35–37] pridobljene s starejšimi baznimi funkcijami [17], razvitimi na podatkovni bazi ESC DB. Te bazne funkcije se raztezajo preko dveh odvodov hkrati (slika 4.3 A). Posledično je možno pričakovati, da bodo takšne bazne funkcije manj natančno zajemale pojav ishemije, saj se spremembe segmenta ST, ki kažejo na ishemijo, pogosto pojavljajo le v enem izmed odvodov, medtem ko so v drugem odvodu manj izrazite ali celo povsem odsotne. Tudi naš preizkus klasifikacije z istimi časovnimi vrstami vektorjev morfoloških značilk, pridobljenih s temi starejšimi baznimi funkcijami na osnovi ESC DB, ki se raztezajo preko dveh odvodov, da znatno nižjo klasifikacijsko točnost  $CA = 73\%$  (tabela 7.6) v primerjavi z novimi prilagodljivimi baznimi funkcijami na posamičnih odvodih in z njimi pridobljenimi značilkami ob enakih postopkih klasifikacije. To je skladno z ugotovitvijo, da so dale predhodne bazne funkcije na osnovi ESC DB dobre rezultate le v kombinaciji z drugimi vrstami značilk in metodami za predobdelavo značilk. Tako je ena izmed prednosti nove metode, ki transformacijo KLT izračunava na posamičnih odvodih in se dinamično prilagaja spreminjajoči se srčni frekvenci, natančnejše razločevanje med segmenti ST, pri katerih so prisotne spremembe morfologije, ki kažejo na ishemijo, od segmentov ST, kjer ni prisotnih ishemičnih sprememb.

Pomembna nadaljnja prednost nove metode je tudi sam ožji nabor značilk, ki je potreben za doseganje visokih točnosti klasifikacije – samo značilke KLT ali LPT. Pridobivanje značilk tako ni odvisno od kaskade več ravni predobdelav, kjer obstaja večja možnost kopičenja napake ter različnih parametrov za umerjanje in podrobno prilagajanje delovanja. Potrebno je le določanje stabilne referenčne točke. Zato je možno pričakovati stabilnejše delovanje na novih podatkih ter v prisotnosti različnih motenj in variabilnosti v signalih EKG. Z metodo za izločanje značilk zgolj v ekstremih epizod brez uporabe značilk v različnih točkah poteka epizode se nadalje izognemo določanju začetkov in koncev epizod, ki je prav tako zahtevno in manj stabilno. Postopek za določanje ekstreme epizode pa je bistveno lažji.

Rezultati testiranja točnosti klasifikacije, ki smo ga izvedli z uveljavljenimi klasifikatorji na primeru klasifikacije med prehodnimi ishemičnimi in neishemičnimi epizodami segmenta ST v podatkovni bazi LTST DB, tako kažejo, da nove metode za dinamično prilagajanje ortogonalnih transformacij srčni frekvenci znatno izboljšajo klasifikacijsko točnost z uporabo značilk, ki smo jih pridobili na njihovi osnovi. Rezul-

tati izmerjene klasifikacijske zmogljivosti nam nakazujejo močne obete za razvoj novih učinkovitejših aplikacij za detekcijo in klasifikacijo prehodnih epizod spremenjene morfologije segmenta ST.

## *Zaključek*

Evaluacija predstavljenih razvitih metod nakazuje na eni strani nove možnosti razvoja orodij za učinkovitejšo ekspertne analize in računalniško podprto ekspertno diagnostiko in na drugi strani možnosti razvoja novih natančnejših avtomatskih analizatorjev in detektorjev.

Eksperti kardiologi bodo lahko s takšnimi orodji analizirali pomembne lastnosti signala v segmentu ST elektrokardiograma zgolj z opazovanjem vizualiziranih trendov časovnih vrst vektorjev morfoloških značilk LPT, ki obsegajo več ur na enem samem prikazu. To je občutno učinkovitejše od analize sprememb morfologije segmenta ST s slik EKG posamičnih srčnih utripov. Elektrokardiogram tipično obsega od 3000 do 5000 slik (in več) srčnih utripov v eni uri. Poleg tega je tako možno preučevati tudi časovni potek (razvoj) teh pojavov. Vizualizirane časovne vrste LPT namreč nudijo popolno sliko morfoloških lastnosti že iz vizualiziranih magnitud koeficientov, medtem ko vizualizirane časovne vrste KLT lahko jasno izpostavijo le nastop spremembe v morfologiji, ne pa njenih diagnostično pomembnih lastnosti.

Transformacija LPT omogoča standardiziran pristop k ocenjevanju morfologije, temelječ na enotni matematično definirani ortogonalni bazi. S tem zagotavlja natančno enotne (ponovljive) rezultate in kompatibilnost (primerljivost) različnih implementacij ter jo je tako mogoče standardizirati kot standardno diagnostično metodo. Hkrati je proces generiranja baznih funkcij LPT razmeroma enostaven v primerjavi z baznimi funkcijami KLT, ki za učinkovito izvedbo potrebujejo več faz razmeroma zahtevnega predprocesiranja in obsežno, primerno reprezentativno podatkovno bazo ekspertno označenih posnetkov EKG. Našteto prav tako predstavlja dodatne stroške. Tako je transformacija LPT tudi z vidika ekonomike in dostopnosti bistveno učinkovitejša.

Razvita nadgradnja algoritmov s prilagajanjem srčni frekvenci je za učinkovito zajemanje morfoloških značilk segmenta ST z ortogonalno transformacijo LPT bistvenega pomena in njeno učinkovitost za računalniško klasifikacijo bistveno izboljša oziroma izenači s KLT.

Ker transformacija LPT nudi možnost vpogleda v oblike in vrste prehodnih sprememb v morfologiji segmenta ST neposredno iz prostora koeficientov transformacije, nam to nakazuje možnosti razvoja novih kliničnih diagnostičnih kriterijev za zanesljivo vizualno detekcijo prehodne ishemije z uporabo LPT. Posledično lahko pričakujemo občutno manj napačno ocenjenih lastnosti segmenta ST.

Pri ocenjevanju pomembnih prehodnih sprememb morfologije segmenta ST na osnovi spreminjajoči se srčni frekvenci prilagodljivega zajemanja informacij s celotnega

segmenta ST lahko ugotovimo, da nove bazne funkcije transformacije LPT omogočajo večjo natančnost ocenjevanja oblik prehodnih sprememb morfologije segmenta ST.

Nove bazne funkcije KLT na osnovi spreminjajoči se srčni frekvenci prilagodljivega zajemanja informacij s celotnega segmenta ST omogočajo visoko klasifikacijsko točnost pri klasifikaciji med prehodnimi ishemičnimi in neishemičnimi epizodami segmenta ST ter tako odpirajo nove možnosti razvoja natančnejših detektorjev prehodne srčne ishemije.

### 9.1 Nadaljnje delo

V nadaljnjem delu bomo razvito metodo za klasifikacijo med prehodnimi ishemičnimi in neishemičnimi epizodami spremenjene morfologije segmenta ST nadgradili z uporabo dodatnih morfoloških in diagnostičnih časovnih vrst. V dosedanjem delu je bil naš cilj razviti metode za natančno opisovanje in klasificiranje morfologije segmenta ST elektrokardiograma. Zato drugih značilk, povezanih z drugimi intervali in kompleksi srčnega utripa, do sedaj nismo uporabljali. Izvedeni preizkus klasifikacije z uporabo časovnih vrst z razširjenim prilagodljivim oknom zajema segmenta ST (tabela 7.5) posredno že uporablja informacijo, ki jo srčni frekvenci prilagodljivo zajememo tudi z dela vala T. Rezultati klasifikacije se tako še nekoliko izboljšajo. To kaže, da so poleg segmenta ST za optimizacijo točnosti klasifikacije med ishemičnimi in neishemičnimi epizodami pomembne še informacije z drugih intervalov elektrokardiograma srčnega utripa (val T, kompleks QRS). Poleg tega pričakujemo, da pomembno informacijo nosi tudi časovna vrsta srčne frekvence sama. To prav tako potrjujejo sorodna dela [35–37], ki uporabljajo značilke tako na osnovi morfologije različnih intervalov elektrokardiograma srčnega utripa kot tudi na osnovi srčne frekvence same. Poleg segmenta ST, ki nosi temeljno informacijo za klasifikacijo med prehodnimi ishemičnimi in neishemičnimi epizodami, saj z uporabo samo morfologije segmenta ST dosežemo klasifikacijsko točnost  $CA = 90\%$ , za dodatno izboljšanje točnosti klasifikacije načrtujemo še uporabo značilk, ki jih bomo pridobili na osnovi kompleksa QRS, samo vala T in srčne frekvence. Morfologijo vala T bomo poslej prav tako lahko opisovali natančno z uporabo novega srčni frekvenci prilagodljivega algoritma, ki ga načrtujemo. Val T namreč v elektrokardiogramu srčnega utripa neposredno sledi koncu segmenta ST, ki ga naša razvita metoda za določanje dolžine segmenta ST že zanesljivo določa.





# *Priloge*

*IO*

10.1 Priloga 1

Podrobnejši izpis rezultatov študije na primeru klasifikacije med prehodnimi ishemičnimi in neishemičnimi epizodami segmenta ST.

Tabela 10.1

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI, katerih funkcijo dolžine segmenta ST v odvisnosti od srčne frekvence spremenimo za faktor  $R$ , s klasifikatorjem K najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosedih z značilkami koeficientov 1–9. V prvi vrsti so za primerjavo dodani tudi rezultati klasifikacije BREZ DINAMIČNEGA PRILAGAJANJA SRČNI FREKVENCI s klasifikatorjem K najbližjih sosedov s  $k = 3$  (3NN\*),  $k = 4$  (4NN\*) in  $k = 5$  (5NN\*) sosedih z značilkami koeficientov 1–9. Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(z dinamičnim prilagajanjem, * brez dinamičnega prilagajanja)			KLT			LPT		
	$R$		$Se$	$Sp$	$CA$	$Se$	$Sp$	$CA$
Coeff. 1–9	3NN*	1	0.91	0.80	0.89	0.86	0.74	0.84
	3NN	0.9	0.79	0.67	0.77	0.88	0.77	0.86
	3NN	1	0.89	0.82	0.88	0.88	0.84	0.87
	3NN	1.25	0.89	0.77	0.87	0.90	0.86	0.89
	3NN	1.5	0.92	0.85	0.91	0.91	0.86	0.90
	3NN	1.75	0.91	0.87	0.90	0.75	0.69	0.74
Coeff. 1–9	4NN*	1	0.89	0.83	0.88	0.82	0.78	0.81
	4NN	0.9	0.85	0.79	0.84	0.86	0.79	0.85
	4NN	1	0.86	0.85	0.86	0.87	0.84	0.87
	4NN	1.25	0.87	0.82	0.86	0.87	0.87	0.87
	4NN	1.5	0.89	0.88	0.89	0.88	0.87	0.88
	4NN	1.75	0.88	0.89	0.88	0.87	0.86	0.87
Coeff. 1–9	5NN*	1	0.87	0.85	0.87	0.78	0.79	0.78
	5NN	0.9	0.83	0.85	0.83	0.83	0.82	0.83
	5NN	1	0.85	0.89	0.85	0.84	0.86	0.84
	5NN	1.25	0.85	0.83	0.84	0.85	0.89	0.85
	5NN	1.5	0.87	0.90	0.88	0.86	0.90	0.87
	5NN	1.75	0.85	0.91	0.86	0.84	0.86	0.84

Tabela 10.2

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT BREZ DINAMIČNEGA PRILAGAJANJA SRČNI FREKVENCI s klasifikatorji Klasifikacijsko drevo (CT), K najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosedi, Linearna diskriminantna analiza (LDA), Naivni Bayesov klasifikator (NBC), Kvadratna diskriminantna analiza (QDA), Metoda podpornih vektorjev z linearnim (SVML) in kvadratnim (SVMQ) jedrom ( $Se$  - Občutljivost,  $Sp$  - Specifičnost,  $CA$  - Klasifikacijska točnost). Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(brez dinamičnega prilagajanja)		KLT			LPT		
		$Se$	$Sp$	$CA$	$Se$	$Sp$	$CA$
Coeff. 1-3	3NN	0.79	0.74	0.78	0.69	0.61	0.68
	4NN	0.76	0.83	0.77	0.64	0.65	0.64
	5NN	0.72	0.86	0.74	0.59	0.73	0.62
	CT	0.82	0.56	0.78	0.78	0.47	0.73
	LDA	0.67	0.59	0.66	0.61	0.50	0.59
	NBC	0.71	0.68	0.70	0.62	0.67	0.63
	QDA	0.53	0.85	0.58	0.47	0.85	0.53
	SVML	0.66	0.62	0.65	0.61	0.51	0.59
	SVMQ	0.72	0.64	0.71	0.59	0.63	0.60
Coeff. 1-5	3NN	0.88	0.82	0.87	0.83	0.75	0.82
	4NN	0.85	0.84	0.85	0.79	0.82	0.79
	5NN	0.82	0.86	0.83	0.75	0.84	0.76
	CT	0.87	0.63	0.83	0.84	0.59	0.80
	LDA	0.74	0.71	0.73	0.62	0.74	0.64
	NBC	0.81	0.69	0.79	0.70	0.70	0.70
	QDA	0.69	0.82	0.71	0.61	0.82	0.65
	SVML	0.72	0.72	0.72	0.62	0.71	0.63
	SVMQ	0.79	0.75	0.78	0.77	0.74	0.76
Coeff. 1-8	3NN	0.91	0.85	0.90	0.85	0.72	0.82
	4NN	0.89	0.85	0.88	0.82	0.79	0.81
	5NN	0.87	0.87	0.87	0.79	0.80	0.79
	CT	0.90	0.68	0.86	0.86	0.56	0.81
	LDA	0.73	0.74	0.74	0.63	0.71	0.65
	NBC	0.83	0.73	0.81	0.74	0.67	0.73
	QDA	0.90	0.53	0.84	0.90	0.40	0.81
	SVML	0.71	0.72	0.71	0.63	0.70	0.64
	SVMQ	0.81	0.76	0.81	0.81	0.74	0.79
Coeff. 1-9	3NN	0.91	0.80	0.89	0.86	0.74	0.84
	4NN	0.89	0.83	0.88	0.82	0.78	0.81
	5NN	0.87	0.85	0.87	0.78	0.79	0.78
	CT	0.88	0.58	0.83	0.85	0.52	0.80
	LDA	0.75	0.72	0.74	0.65	0.66	0.65
	NBC	0.84	0.71	0.82	0.78	0.67	0.76
	QDA	0.92	0.43	0.84	0.89	0.35	0.79
	SVML	0.71	0.73	0.71	0.63	0.71	0.65
	SVMQ	0.81	0.75	0.80	0.83	0.72	0.81

Tabela 10.3

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT **Z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI** s klasifikatorji Klasifikacijsko drevo (CT), K najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosed, Linearna diskriminantna analiza (LDA), Naivni Bayesov klasifikator (NBC), Kvadratna diskriminantna analiza (QDA), Metoda podpornih vektorjev z linearnim (SVML) in kvadratnim (SVMQ) jedrom (*Se* - Občutljivost, *Sp* - Specifičnost, *CA* - Klasifikacijska točnost). Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(z dinamičnim prilagajanjem)		KLT			LPT		
		<i>Se</i>	<i>Sp</i>	<i>CA</i>	<i>Se</i>	<i>Sp</i>	<i>CA</i>
Coeff. 1-3	3NN	0.76	0.78	0.76	0.76	0.75	0.76
	4NN	0.72	0.85	0.74	0.70	0.80	0.72
	5NN	0.68	0.85	0.71	0.66	0.83	0.69
	CT	0.83	0.59	0.79	0.83	0.63	0.80
	LDA	0.69	0.59	0.67	0.69	0.59	0.67
	NBC	0.74	0.66	0.72	0.72	0.66	0.71
	QDA	0.58	0.85	0.62	0.54	0.85	0.60
	SVML	0.66	0.60	0.65	0.67	0.60	0.65
	SVMQ	0.57	0.47	0.55	0.71	0.65	0.70
Coeff. 1-5	3NN	0.86	0.85	0.86	0.85	0.84	0.85
	4NN	0.82	0.89	0.83	0.82	0.84	0.82
	5NN	0.79	0.89	0.81	0.79	0.87	0.80
	CT	0.87	0.64	0.83	0.88	0.60	0.83
	LDA	0.75	0.69	0.74	0.75	0.72	0.74
	NBC	0.79	0.73	0.78	0.76	0.69	0.75
	QDA	0.79	0.75	0.78	0.87	0.63	0.83
	SVML	0.73	0.70	0.73	0.74	0.70	0.73
	SVMQ	0.62	0.50	0.60	0.77	0.74	0.76
Coeff. 1-8	3NN	0.89	0.82	0.88	0.89	0.83	0.88
	4NN	0.86	0.87	0.86	0.86	0.86	0.86
	5NN	0.84	0.86	0.84	0.84	0.86	0.84
	CT	0.87	0.59	0.82	0.87	0.60	0.83
	LDA	0.75	0.71	0.74	0.75	0.71	0.74
	NBC	0.81	0.75	0.80	0.80	0.66	0.77
	QDA	0.92	0.38	0.82	0.92	0.34	0.82
	SVML	0.75	0.70	0.74	0.74	0.70	0.73
	SVMQ	0.57	0.50	0.56	0.79	0.77	0.79
Coeff. 1-9	3NN	0.89	0.82	0.88	0.88	0.84	0.87
	4NN	0.86	0.85	0.86	0.87	0.84	0.87
	5NN	0.85	0.89	0.85	0.84	0.86	0.84
	CT	0.87	0.61	0.83	0.86	0.62	0.82
	LDA	0.75	0.69	0.74	0.75	0.70	0.74
	NBC	0.81	0.74	0.80	0.81	0.68	0.79
	QDA	0.91	0.37	0.82	0.92	0.35	0.83
	SVML	0.75	0.68	0.74	0.74	0.71	0.74
	SVMQ	0.59	0.47	0.57	0.81	0.79	0.81

Tabela 10.4

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacije KLT s predhodnimi baznimi funkcijami pridobljenimi na podatkovni bazi ESC DB, ki so jih uporabljali starejši algoritmi, **BREZ DINAMIČNEGA PRILAGAJANJA SRČNI FREKVENCI**, s klasifikatorji Klasifikacijsko drevo (CT), K najbližjih sosedov s  $k = 3$  (3NN) sosedih, Linearna diskriminantna analiza (LDA), Naivni Bayesov klasifikator (NBC), Kvadratna diskriminantna analiza (QDA), Metoda podpornih vektorjev z linearnim (SVML) in kvadratnim (SVMQ) jedrom na časovnih vrstah vektorjev morfoloških značilk KLT ( $Se$  - Občutljivost,  $Sp$  - Specifičnost,  $CA$  - Klasifikacijska točnost). Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(brez dinamičnega prilagajanja)		KLT		
		$Se$	$Sp$	$CA$
Coeff. 1-3	3NN	0.63	0.68	0.64
	CT	0.74	0.38	0.67
	LDA	0.34	0.65	0.40
	NBC	0.52	0.79	0.58
	QDA	0.31	0.86	0.42
	SVML	0.34	0.64	0.40
	SVMQ	0.55	0.51	0.54
Coeff. 1-5	3NN	0.66	0.68	0.67
	CT	0.75	0.39	0.68
	LDA	0.60	0.82	0.65
	NBC	0.49	0.78	0.55
	QDA	0.55	0.86	0.61
	SVML	0.60	0.81	0.64
	SVMQ	0.54	0.46	0.52
Coeff. 1-8	3NN	0.66	0.72	0.67
	CT	0.75	0.48	0.70
	LDA	0.59	0.80	0.63
	NBC	0.48	0.82	0.54
	QDA	0.59	0.85	0.64
	SVML	0.59	0.83	0.64
	SVMQ	0.49	0.40	0.48
Coeff. 1-9	3NN	0.66	0.75	0.68
	CT	0.78	0.53	0.73
	LDA	0.61	0.78	0.64
	NBC	0.47	0.80	0.54
	QDA	0.59	0.87	0.64
	SVML	0.59	0.77	0.62
	SVMQ	0.60	0.42	0.56

Tabela 10.5

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI z uporabo zgolj matematičnega modela, ki smo ga izpeljali na osnovi Bazettrove formule (3.34), s klasifikatorji Klasifikacijsko drevo (CT), K najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosedih, Linearna diskriminantna analiza (LDA), Naivni Bayesov klasifikator (NBC), Kvadratna diskriminantna analiza (QDA), Metoda podpornih vektorjev z linearnim (SVML) in kvadratnim (SVMQ) jedrom ( $Se$  - Občutljivost,  $Sp$  - Specifičnost,  $CA$  - Klasifikacijska točnost). Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(z dinamičnim prilagajanjem)		KLT			LPT		
		$Se$	$Sp$	$CA$	$Se$	$Sp$	$CA$
Coeff. 1-3	3NN	0.80	0.77	0.79	0.79	0.76	0.78
	4NN	0.75	0.85	0.76	0.74	0.82	0.75
	5NN	0.71	0.85	0.73	0.69	0.83	0.72
	CT	0.84	0.59	0.80	0.86	0.58	0.82
	LDA	0.70	0.65	0.70	0.70	0.64	0.69
	NBC	0.73	0.69	0.72	0.73	0.70	0.73
	QDA	0.61	0.83	0.65	0.59	0.83	0.63
	SVML	0.70	0.64	0.69	0.68	0.63	0.67
	SVMQ	0.63	0.44	0.60	0.66	0.50	0.63
Coeff. 1-5	3NN	0.85	0.82	0.85	0.85	0.80	0.84
	4NN	0.82	0.85	0.82	0.81	0.85	0.82
	5NN	0.79	0.89	0.81	0.79	0.86	0.80
	CT	0.86	0.59	0.81	0.85	0.65	0.82
	LDA	0.74	0.69	0.73	0.75	0.72	0.74
	NBC	0.79	0.73	0.78	0.75	0.68	0.74
	QDA	0.84	0.65	0.81	0.86	0.59	0.81
	SVML	0.72	0.69	0.71	0.74	0.72	0.74
	SVMQ	0.60	0.53	0.58	0.59	0.45	0.57
Coeff. 1-8	3NN	0.88	0.79	0.86	0.89	0.79	0.87
	4NN	0.85	0.82	0.84	0.86	0.82	0.85
	5NN	0.83	0.85	0.83	0.83	0.86	0.83
	CT	0.86	0.62	0.82	0.87	0.56	0.82
	LDA	0.75	0.71	0.74	0.75	0.72	0.75
	NBC	0.81	0.74	0.79	0.79	0.66	0.77
	QDA	0.90	0.39	0.81	0.93	0.32	0.82
	SVML	0.75	0.71	0.74	0.74	0.72	0.74
	SVMQ	0.64	0.55	0.63	0.55	0.50	0.54
Coeff. 1-9	3NN	0.88	0.76	0.86	0.89	0.79	0.87
	4NN	0.86	0.82	0.85	0.86	0.82	0.86
	5NN	0.83	0.82	0.83	0.83	0.85	0.83
	CT	0.85	0.57	0.80	0.88	0.59	0.83
	LDA	0.76	0.67	0.74	0.75	0.69	0.74
	NBC	0.81	0.70	0.79	0.80	0.69	0.78
	QDA	0.92	0.35	0.82	0.92	0.33	0.82
	SVM	0.76	0.69	0.75	0.74	0.70	0.73
	SVMQ	0.63	0.50	0.60	0.55	0.56	0.55

Tabela 10.6

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT **Z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI** s klasifikatorjem K najbližjih sosedov s  $k = 3$  (3NN) sosedih z značilkami izbranih podmnožic koeficientov 1–3, 1–4, 1–5, ..., 1–9. Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(z dinamičnim prilagajanjem)			KLT			LPT		
			Se	Sp	CA	Se	Sp	CA
Coeff. 1–3	3NN		0.76	0.78	0.76	0.76	0.75	0.76
Coeff. 1–4	3NN		0.81	0.83	0.81	0.83	0.82	0.83
Coeff. 1–5	3NN		0.86	0.85	0.86	0.85	0.84	0.85
Coeff. 1–6	3NN		0.88	0.84	0.88	0.86	0.81	0.85
Coeff. 1–7	3NN		0.89	0.84	0.88	0.87	0.83	0.86
Coeff. 1–8	3NN		0.89	0.82	0.88	0.89	0.83	0.88
Coeff. 1–9	3NN		0.89	0.82	0.88	0.88	0.84	0.87

Tabela 10.7

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT **Z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI**, katerih funkcijo dolžine segmenta ST v odvisnosti od srčne frekvence spremenimo za faktor  $R = 0.9$ , s klasifikatorji K najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosedih (*Se* - Občutljivost, *Sp* - Specifičnost, *CA* - Klasifikacijska točnost). Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(z dinamičnim prilagajanjem, $R = 0.9$ )		KLT			LPT		
		Se	Sp	CA	Se	Sp	CA
Coeff. 1–3	4NN	0.77	0.83	0.78	0.75	0.79	0.76
	5NN	0.72	0.84	0.74	0.72	0.84	0.74
Coeff. 1–5	4NN	0.82	0.82	0.82	0.81	0.83	0.81
	5NN	0.79	0.85	0.80	0.78	0.85	0.79
Coeff. 1–8	4NN	0.86	0.80	0.85	0.85	0.82	0.84
	5NN	0.83	0.80	0.83	0.82	0.84	0.83
Coeff. 1–9	3NN	0.79	0.67	0.77	0.88	0.77	0.86
	4NN	0.85	0.79	0.84	0.86	0.79	0.85
	5NN	0.83	0.85	0.83	0.83	0.82	0.83

Tabela 10.8

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI, katerih funkcijo dolžine segmenta ST v odvisnosti od srčne frekvence spremenimo za faktor  $R = 1.5$ , s klasifikatorji Klasifikacijsko drevo (CT), K najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosedi, Linearna diskriminantna analiza (LDA), Naivni Bayesov klasifikator (NBC), Kvadratna diskriminantna analiza (QDA), Metoda podpornih vektorjev z linearnim (SVML) in kvadratnim (SVMQ) jedrom ( $Se$  - Občutljivost,  $Sp$  - Specifičnost,  $CA$  - Klasifikacijska točnost). Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(z dinamičnim prilagajanjem, $R = 1.5$ )		KLT			LPT		
		$Se$	$Sp$	$CA$	$Se$	$Sp$	$CA$
Coeff. 1-3	3NN	0.75	0.72	0.75	0.76	0.72	0.75
	4NN	0.71	0.75	0.71	0.70	0.77	0.71
	5NN	0.68	0.80	0.70	0.65	0.79	0.68
	CT	0.83	0.58	0.79	0.82	0.54	0.77
	LDA	0.69	0.63	0.68	0.70	0.69	0.70
	NBC	0.70	0.74	0.70	0.75	0.64	0.73
	QDA	0.55	0.85	0.60	0.55	0.85	0.60
	SVML	0.69	0.67	0.68	0.69	0.72	0.70
	SVMQ	0.55	0.48	0.54	0.72	0.74	0.73
Coeff. 1-5	3NN	0.89	0.89	0.89	0.88	0.86	0.88
	4NN	0.87	0.91	0.88	0.85	0.88	0.86
	5NN	0.85	0.93	0.86	0.83	0.91	0.84
	CT	0.90	0.68	0.87	0.89	0.65	0.85
	LDA	0.74	0.77	0.75	0.74	0.77	0.74
	NBC	0.80	0.79	0.80	0.75	0.77	0.76
	QDA	0.68	0.87	0.71	0.69	0.88	0.72
	SVML	0.74	0.79	0.75	0.74	0.79	0.75
	SVMQ	0.56	0.48	0.54	0.78	0.77	0.78
Coeff. 1-8	3NN	0.91	0.84	0.90	0.90	0.85	0.89
	4NN	0.90	0.90	0.90	0.88	0.90	0.88
	5NN	0.87	0.91	0.87	0.85	0.88	0.85
	CT	0.89	0.71	0.86	0.89	0.67	0.85
	LDA	0.76	0.77	0.76	0.75	0.79	0.76
	NBC	0.83	0.82	0.83	0.77	0.75	0.77
	QDA	0.91	0.59	0.85	0.90	0.58	0.85
	SVML	0.75	0.79	0.75	0.74	0.80	0.75
	SVMQ	0.59	0.47	0.57	0.81	0.79	0.80
Coeff. 1-9	3NN	0.92	0.85	0.91	0.91	0.86	0.90
	4NN	0.89	0.88	0.89	0.88	0.87	0.88
	5NN	0.87	0.90	0.88	0.86	0.90	0.87
	CT	0.90	0.67	0.86	0.88	0.68	0.85
	LDA	0.76	0.77	0.76	0.75	0.79	0.76
	NBC	0.84	0.80	0.83	0.80	0.75	0.79
	QDA	0.91	0.49	0.84	0.92	0.52	0.85
	SVML	0.74	0.79	0.75	0.74	0.79	0.75
	SVMQ	0.59	0.51	0.58	0.80	0.79	0.80



Tabela 10.9

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI, katerih funkcijo dolžine segmenta ST v odvisnosti od srčne frekvence spremenimo za faktor  $R = 1.25$ , s klasifikatorji K najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosedi ( $Se$  - Občutljivost,  $Sp$  - Specifičnost,  $CA$  - Klasifikacijska točnost). Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(z dinamičnim prilagajanjem, $R = 1.25$ )		KLT			LPT		
		$Se$	$Sp$	$CA$	$Se$	$Sp$	$CA$
Coeff. 1-3	4NN	0.74	0.83	0.76	0.71	0.80	0.73
	5NN	0.68	0.85	0.71	0.66	0.84	0.69
Coeff. 1-5	4NN	0.83	0.87	0.84	0.84	0.85	0.84
	5NN	0.80	0.88	0.81	0.80	0.86	0.81
Coeff. 1-8	4NN	0.87	0.83	0.87	0.87	0.89	0.87
	5NN	0.85	0.86	0.85	0.85	0.92	0.86
Coeff. 1-9	3NN	0.89	0.77	0.87	0.90	0.86	0.89
	4NN	0.87	0.82	0.86	0.87	0.87	0.87
	5NN	0.85	0.83	0.84	0.85	0.89	0.85

Tabela 10.10

Rezultati testiranja zmogljivosti klasifikacije med ishemičnimi in neishemičnimi epizodami segmenta ST z značilkami na osnovi transformacij KLT in LPT z DINAMIČNIM PRILAGAJANJEM SRČNI FREKVENCI, katerih funkcijo dolžine segmenta ST v odvisnosti od srčne frekvence spremenimo za faktor  $R = 1.75$ , s klasifikatorji K najbližjih sosedov s  $k = 3$  (3NN),  $k = 4$  (4NN) in  $k = 5$  (5NN) sosedi ( $Se$  - Občutljivost,  $Sp$  - Specifičnost,  $CA$  - Klasifikacijska točnost). Rezultati klasifikatorja z najvišjo točnostjo so obarvani.

(z dinamičnim prilagajanjem, $R = 1.75$ )		KLT			LPT		
		$Se$	$Sp$	$CA$	$Se$	$Sp$	$CA$
Coeff. 1-3	4NN	0.73	0.78	0.74	0.70	0.80	0.72
	5NN	0.69	0.80	0.71	0.66	0.85	0.69
Coeff. 1-5	4NN	0.84	0.91	0.85	0.82	0.85	0.82
	5NN	0.81	0.91	0.83	0.78	0.88	0.80
Coeff. 1-8	4NN	0.87	0.89	0.87	0.86	0.86	0.86
	5NN	0.85	0.92	0.86	0.84	0.88	0.85
Coeff. 1-9	3NN	0.91	0.87	0.90	0.75	0.69	0.74
	4NN	0.88	0.89	0.88	0.87	0.86	0.87
	5NN	0.85	0.91	0.86	0.84	0.86	0.84



# LITERATURA

- [1] W. Einthoven. Die galvanometrische registrirung des menschlichen elektrokardiogramms, zugleich eine beurtheilung der anwendung des capillar-elektrometers in der physiologie. *Archiv für die gesamte Physiologie des Menschen und der Tiere*, 99(9):472–480, 1903. ISSN 1432-2013. doi: [10.1007/BF01811855](https://doi.org/10.1007/BF01811855).
- [2] J. T. Willerson, J. N. Cohn, H. J. J. Wellens, and D. R. Holmes. *Cardiovascular Medicine*. SpringerLink : Bücher. Springer London, 2007. ISBN 9781846287152.
- [3] F. Jager. *Automated detection of transient ST-segment changes during ambulatory ECG-monitoring*. PhD thesis, Univerza v Ljubljani, Fakulteta za elektrotehniko in računalništvo, Ljubljana, Slovenija, 1994.
- [4] Anatomy & physiology, 2013. URL <http://cnx.org/content/col11496/>.
- [5] L. Sörnmo and P. Laguna. *Bioelectrical Signal Processing in Cardiac and Neurological Applications*. Elsevier Inc., 2005. ISBN 978-0-12-437552-9.
- [6] P. Kumar and M. Clark. *Clinical medicine: A textbook for medical students and doctors*. Bailliere Tindall, London, 1994. ISBN 978-0702026065.
- [7] G. D. Clifford, F. Azuaje, and P. E. McSharry (editors). *Advanced Methods and Tools for ECG Data*. Artech House, Inc., 2006. ISBN 978-1580539661.
- [8] H. C. Bazett. An analysis of the time-relations of electrocardiograms. *Heart*, 7:353–370, 1920.
- [9] D. L. Musat, M. Adhaduk, M. W. Preminger, A. Arshad, T. Sichrovsky, J. S. Steinberg, and S. Mittal. Correlation of QT interval correction methods during atrial fibrillation and sinus rhythm. *The American Journal of Cardiology*, 112(9):1379–1383, nov 2013. doi: [10.1016/j.amjcard.2013.06.027](https://doi.org/10.1016/j.amjcard.2013.06.027).
- [10] F. Jager, A. Taddei, G. B. Moody, M. Emdin, G. Anolčić, R. Dorn, A. Smrdel, C. Marchesi, and R. G. Mark. Long-term ST database: A reference for the development and evaluation of automated ischaemia detectors and for the study of the dynamics of myocardial ischaemia. *Medical and Biological Engineering and Computing*, 41(2):172–182, 2003. ISSN 0140-0118. doi: [10.1007/BF02344885](https://doi.org/10.1007/BF02344885).
- [11] A. Taddei, G. Distanti, M. Emdin, P. Pisani, G. B. Moody, C. Zeelenberg, and C. Marchesi. The european ST-T database: standard for evaluating systems for the analysis of ST-T changes in ambulatory electrocardiography. *European Heart Journal*, 13(9):1164–1172, 1992. ISSN 0195-668X.
- [12] A. Taddei, G. Constantino, R. Silipo, M. Emdin, and C. Marchesi. A system for the detection of ischemic episodes in ambulatory ECG. In *Computing in Cardiology*, pages 705–708, Los Alamitos, 1995. IEEE Computer Society Press.
- [13] J. García, L. Sörnmo, S. Olmos, and P. Laguna. Automatic detection of ST-T complex changes on the ECG using filtered rms difference series: application to ambulatory ischemia monitoring. *IEEE Transactions on Biomedical Engineering*, 47:1195–1201, 2000. doi: [10.1109/10.867943](https://doi.org/10.1109/10.867943).
- [14] R. W. Stadler, S. N. Lu, S. D. Nelson, and L. Stylos. A real-time ST-segment monitoring algorithm for implantable devices. *Journal of Electrocardiology*, 34:119–126, 2001.
- [15] A. Kumar and M. Singh. Statistical analysis of ST segments in ECG signals for detection of ischaemic episodes. *Transactions of the Institute of Measurement and Control*, page 0142331216667811, 2016. doi: [10.1177/0142331216667811](https://doi.org/10.1177/0142331216667811).
- [16] F. Jager, R. G. Mark, G. B. Moody, and S. Divjak. Analysis of transient ST segment changes during ambulatory ECG monitoring using the karhunen-loève transform. In *Computing in Cardiology*, pages 691–694. IEEE Computer Society Press, 1992.
- [17] F. Jager, G. B. Moody, and R. G. Mark. Detection of transient ST segment episodes during ambulatory ECG

- monitoring. *Computers and Biomedical Research*, 31(5): 305–322, 1998. ISSN 0010-4809. doi: [10.1006/cbmr.1998.1483](https://doi.org/10.1006/cbmr.1998.1483).
- [18] A. Smrdel and F. Jager. Automated detection of transient ST-segment episodes in 24h electrocardiograms. *Medical and Biological Engineering and Computing*, 42(3):303–311, 2004. ISSN 0140-0118. doi: [10.1007/BF02344704](https://doi.org/10.1007/BF02344704).
- [19] N. Maglaveras, T. Stamkopoulos, C. Pappas, and M. G. Strintzis. An adaptive backpropagation neural network for real-time ischemia episodes detection: Development and performance analysis using the european ST-T database. *IEEE Transactions on Biomedical Engineering*, 45:805–813, 1998. doi: [10.1109/10.686788](https://doi.org/10.1109/10.686788).
- [20] R. Silipo and C. Marchesi. Artificial neural networks for automatic ECG analysis. *IEEE Transactions on Signal Processing*, 46:1417–25, 1998. doi: [10.1109/78.668803](https://doi.org/10.1109/78.668803).
- [21] G. Y. Jeong, K. H. Yu, and N. G. Kim. A polynomial approximation approach for analyzing ST shape change. In *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference*, pages 4034–4037, 2005. doi: [10.1109/IEMBS.2005.1615347](https://doi.org/10.1109/IEMBS.2005.1615347).
- [22] J. T. Y. Weng, J. J. Lin, Y. C. Chen, and P. C. Chang. *Myocardial Infarction Classification by Morphological Feature Extraction from Big 12-Lead ECG Data*. Springer International Publishing, 2014. ISBN 978-3-319-13186-3.
- [23] S. L. Kasar and M. S. Joshi. Improved model for the detection of myocardial infarction from multilead eeg using QRS point score as an additional feature. *Journal of Theoretical and Applied Information Technology*, 85(2): 183, 2016.
- [24] H. Rabbani, M. P. Mahjoob, E. Farahabadi, A. Farahabadi, and A. M. Dehnavi. Ischemia detection by electrocardiogram in wavelet domain using entropy measure. *Journal of Research in Medical Sciences*, 16(11): 1473–82, 2011.
- [25] L. Dranca, A. Goñi, and A. Illarramendi. Real-time detection of transient cardiac ischemic episodes from ECG signals. *Physiological Measurement*, 30(9):983, 2009. doi: [10.1088/0967-3334/30/9/009](https://doi.org/10.1088/0967-3334/30/9/009).
- [26] L. Dranca, A. Goñi, and A. Illarramendi. Tuning a real-time detector of transient cardiac ischemic episodes on the long-term ST database according to the annotation protocol b. In *Computing in Cardiology 2013*, pages 583–586, 2013.
- [27] G. B. Moody and R. G. Mark. QRS morphology representation and noise estimation using the karhunen-loève transform. In *Computing in Cardiology*, pages 269–272. IEEE, 1989. doi: [10.1109/CIC.1989.130540](https://doi.org/10.1109/CIC.1989.130540).
- [28] M. Buemi, A. Macerata, A. Taddei, M. Varanini, M. Emdin, and C. Marchesi. Monitoring patient status through principal components analysis. In *Computing in Cardiology*, pages 385–388. IEEE Computer Society Press, Sep 1991. doi: [10.1109/CIC.1991.169125](https://doi.org/10.1109/CIC.1991.169125).
- [29] A. Taddei, M. Emdin, M. Varanini, A. Macerata, P. Pisani, E. Santarcangelo, and C. Marchesi. An approach to cardiorespiratory activity monitoring through principal component analysis. *Journal of Ambulatory Monitoring*, 5(2-3):167–173, 1992.
- [30] P. Laguna, G. B. Moody, and R. G. Mark. Analysis of the cardiac repolarization period using the KL transform: applications on the ST-T database. In *Computing in Cardiology*, pages 233–236, Sept 1994. doi: [10.1109/CIC.1994.470207](https://doi.org/10.1109/CIC.1994.470207).
- [31] J. García, S. Olmos, G. B. Moody, R. G. Mark, and P. Laguna. Adaptive estimation of karhunen-loève series applied to the study of ischemic ECG records. In *Computing in Cardiology*, pages 249–252, Sept 1996. doi: [10.1109/CIC.1996.542520](https://doi.org/10.1109/CIC.1996.542520).
- [32] J. García, P. Lander, L. Sörnmo, S. Olmos, G. Wagner, and P. Laguna. Comparative study of local and karhunen-loève-based ST-T indexes in recordings from human subjects with induced myocardial ischemia. *Computers and Biomedical Research*, 31(4):271–292, 1998. doi: [10.1006/cbmr.1998.1481](https://doi.org/10.1006/cbmr.1998.1481).
- [33] P. Laguna, G. B. Moody, J. García, A. L. Goldberger, and R. G. Mark. Analysis of the ST-T complex of the electrocardiogram using the karhunen-loève transform: adaptive monitoring and alternans detection. *Medical and Biological Engineering and Computing*, 37(2):175–189, 1999. ISSN 0140-0118. doi: [10.1007/BF02513285](https://doi.org/10.1007/BF02513285).
- [34] S. Murugan and S. Radhakrishnan. Improving ischemic beat classification using fuzzy-genetic based PCA and ICA. *International Journal on Computer Science and Engineering*, 2(5):1532–1538, 2010.
- [35] J. Faganeli and F. Jager. Automatic classification of transient ischaemic and transient non-ischaemic heart-rate related ST segment deviation episodes in ambulatory ECG records. *Physiological Measurement*, 31(3):323, 2010.
- [36] A. Mincholé, F. Jager, and P. Laguna. Discrimination between ischemic and artifactual ST segment events in holter recordings. *Biomedical Signal Processing and Control*, 5(1):21–31, 2010. ISSN 1746-8094. doi: [10.1016/j.bspc.2009.09.001](https://doi.org/10.1016/j.bspc.2009.09.001).
- [37] C. B. Vilakazi, L. Tarassenko, and G. D. Clifford. Distinguishing between supply ischaemic and non-supply ischaemic ST events using a relevance vector machine. In *Computing in Cardiology*, pages 633–636, Sept 2011.

- [38] F. Hu, C. Li, Y. Zhang, D. Jin, Z. Ma, Y. Sun, and J. Wang. A morphological classification method of ECG ST-segment based on curvature scale space. *Journal of Biosciences and Medicines*, 3:38–43, 2015. doi: [10.4236/jbm.2015.39006](https://doi.org/10.4236/jbm.2015.39006).
- [39] M. Xu, S. Wei, X. Qin, Y. Zhang, and C. Liu. Rule-based method for morphological classification of ST segment in ECG signals. *Journal of Medical and Biological Engineering*, 35(6):816–823, 2015. ISSN 2199-4757. doi: [10.1007/s40846-015-0092-x](https://doi.org/10.1007/s40846-015-0092-x).
- [40] S. Fan, F. Miao, R. Ma, Y. Li, and X. Huang. A multi-feature based morphological algorithm for ST shape classification. In *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 5834–7, 2015. doi: [10.1109/EMBC.2015.7319718](https://doi.org/10.1109/EMBC.2015.7319718).
- [41] G. Y. Jeong, K. H. Yu, and M. J. Yoon. ST shape classification in ECG by constructing reference ST set. *Medical Engineering and Physics*, 32(9):1025–1031, 2010. doi: [10.1016/j.medengphy.2010.07.003](https://doi.org/10.1016/j.medengphy.2010.07.003).
- [42] P. Laguna, R. Jané, S. Olmos, N. V. Thakor, H. Rix, and P. Caminal. Adaptive estimation of QRS complex wave features of ECG signal by the hermite model. *Medical and Biological Engineering and Computing*, 34(1):58–68, 1996. ISSN 0140-0118. doi: [10.1007/BF02637023](https://doi.org/10.1007/BF02637023).
- [43] M. Lagerholm, C. Peterson, G. Braccini, L. Edenbrandt, and L. Sörnmo. Clustering ECG complexes using hermite functions and self-organizing maps. *IEEE Transactions on Biomedical Engineering*, 47(7):838–848, Jul 2000. ISSN 0018-9294. doi: [10.1109/10.846677](https://doi.org/10.1109/10.846677).
- [44] G. Georgiev, I. Valova, N. Gueorgieva, and L. Lei. QRS complex detector implementing orthonormal functions. *Procedia Computer Science*, 12(0):426–431, 2012. ISSN 1877-0509. doi: [10.1016/j.procs.2012.09.099](https://doi.org/10.1016/j.procs.2012.09.099).
- [45] E. W. Weistein. Chebyshev polynomial of the first kind., 2017. URL <http://mathworld.wolfram.com/ChebyshevPolynomialoftheFirstKind.html>.
- [46] M. B. Oefinger. *Monitoring Transient Repolarization Segment Morphology Deviations in Mouse ECG*. PhD thesis, Massachusetts Institute of Technology, 2006.
- [47] E. W. Weistein. Legendre polynomial.” from mathworld—a wolfram web resource, 2017. URL <http://mathworld.wolfram.com/LegendrePolynomial.html>.
- [48] C. Hwang and K. K. Shyu. Analysis and identification of discrete time systems via discrete legendre orthogonal polynomials. *International Journal of Systems Science*, 18(8):1411–1423, 1987. doi: [10.1080/00207178708967121](https://doi.org/10.1080/00207178708967121).
- [49] A. A. Colomer and Colomer A. A. Adaptive ECG data compression using discrete legendre transform. *Digital Signal Processing*, 7:222–228, 1997. doi: [10.1006/dspt.1997.0295](https://doi.org/10.1006/dspt.1997.0295).
- [50] I. Khalil and F. Sufi. Legendre polynomials based biometric authentication using QRS complex of ECG. In *4th Int. Conference on Intelligent Sensors, Sensor Networks and Information Processing, ISSNIP 2008, Melbourne*, 2008.
- [51] A. Gallino, S. Chierchia, G. Smith, M. Croom, M. Morgan, C. Marchesi, and Maseri A. Computer system for analysis of ST segment changes on 24 hour holter monitor tapes: Comparison with other available systems. *Journal of the American College of Cardiology*, 4(2):245–252, 1984. doi: [10.1016/S0735-1097\(84\)80209-0](https://doi.org/10.1016/S0735-1097(84)80209-0).
- [52] R. Dorn and F. Jager. Semia: semi-automatic interactive graphic editing tool to annotate ambulatory ECG records. *Computer Methods and Programs in Biomedicine*, 75(3):235–249, 2004. ISSN 0169-2607. doi: [10.1016/j.cmpb.2004.02.005](https://doi.org/10.1016/j.cmpb.2004.02.005).
- [53] A. L. Goldberger, L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. Ch. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C.-K. Peng, and H. E. Stanley. PhysioBank, physiotookit, and physionet: Components of a new research resource for complex physiologic signals. *Circulation*, 101(23):215–220, 2000. doi: [10.1161/01.CIR.101.23.e215](https://doi.org/10.1161/01.CIR.101.23.e215).
- [54] G. B. Moody and R. G. Mark. Development and evaluation of a 2-lead ECG analysis program. In *Computing in Cardiology*, volume 9, pages 39–44, 1982.
- [55] G.B. Moody and R.G. Mark. The MIT-BIH arrhythmia database on CD-ROM and software for use with it. In *Computing in Cardiology*, pages 185–188, Sep 1990. doi: [10.1109/CIC.1990.144205](https://doi.org/10.1109/CIC.1990.144205).
- [56] G. B. Moody. WFDB programmer’s guide (tenth edition), 2017. URL <http://www.physionet.org/physiotools/wpg/wpg.htm>.
- [57] J. M. Maruskin. *Essential Linear Algebra*. Solar Crest Publishing, LLC, 2012. ISBN 9780985062736.
- [58] P. M. Cohn. *Elements of Linear Algebra*. Chapman Hall/CRC Mathematics Series. Taylor & Francis, 1994. ISBN 9780412552809.
- [59] L. N. Trefethen and D. Bau. *Numerical Linear algebra*. SIAM, 1997. ISBN 978-0898713619.
- [60] A. V. Oppenheim, R. W. Schaffer, and J. R. Buck. *Discrete-time Signal Processing (2Nd Ed.)*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA, 1999. ISBN 0-13-754920-2.

- [61] F. Jager, A. Taddei, M. Emdin, G. Antolić, G. B. Moody, B. Glavić, A. Smrdel, M. Varanini, M. Zabukovec, S. Bordigiago, C. Marchesi, and R. G. Mark. The long-term ST database: A research resource for algorithm development and physiologic studies of transient myocardial ischemia. In *Computing in Cardiology*, pages 841–844. IEEE Society Press, 2000.
- [62] J. T. Tou and R. C. Gonzales. *Pattern Recognition Principles*. Addison Wesley, Massachussets, 1974. ISBN 9780201075861.
- [63] J. Kittler and P. C. Young. A new approach to feature selection based on the karhunen-loève expansion. *Pattern Recognition*, 5(4):335–352, 1973. doi: [10.1016/0031-3203\(73\)90025-3](https://doi.org/10.1016/0031-3203(73)90025-3).
- [64] W. H. Press, S. A. Teukolsky, W. T. Vetterling, and B. P. Flannery. *Numerical Recipes in C*. Cambridge University Press, 2002. ISBN 0-521-43108-5.
- [65] S. J. Devlin, R. Gnanadesikan, and J. R. Kettenring. Robust estimation of dispersion matrices and principal components. *Journal of the American Statistical Association*, 76(374):354–362, 1981. doi: [10.1080/01621459.1981.10477654](https://doi.org/10.1080/01621459.1981.10477654).
- [66] B. Orel. *Osnove numerične matematike*. Založba FE in FRI, Univerza v Ljubljani, Fakulteta za računalništvo in informatiko, 2004. ISBN 961-6209-19-1.
- [67] E. W. Weisstein. Gram-schmidt orthonormalization." from mathworld—a wolfram web resource, 2017. URL <http://mathworld.wolfram.com/Gram-SchmidtOrthonormalization.html>.
- [68] M. Amon and F. Jager. Electrocardiogram ST-segment morphology delineation method using orthogonal transformations. *PLoS ONE*, 11(2), 02 2016. doi: [10.1371/journal.pone.0148814](https://doi.org/10.1371/journal.pone.0148814).
- [69] S. M. Narayan. T-wave alternans and the susceptibility to ventricular arrhythmias. *Journal of the American College of Cardiology*, 47(2):269 – 281, 2006. ISSN 0735-1097. doi: [10.1016/j.jacc.2005.08.066](https://doi.org/10.1016/j.jacc.2005.08.066).